



**Bruno Miguel
Quintela Bastos**

**Autenticação Biométrica Através da Actividade
Cerebral**



**Bruno Miguel
Quintela Bastos**

Autenticação Biométrica Através das Respostas Cerebrais a Estimulos Visuais

Dissertação apresentada à Universidade de Aveiro para cumprimento dos requisitos necessários à obtenção do grau de Mestre em Eng. De Computadores e Telemática, realizada sob a orientação científica do Dr. André Zúquete e co-orientação do Dr. João Paulo Cunha, Professores do Departamento de Electrónica, Telecomunicações e Informática (DETI) e Instituto de Engenharia de Electrónica e Telemática de Aveiro (IEETA).

“ Vejo o mundo como sou, não como é.”

Paul Eluard

agradecimentos

Ao orientador, Dr. André Zúquete, por todo o apoio e disponibilidade que me concedeu durante a elaboração desta tese.

Ao professor Henri Begleiter (*at Neurodynamics Laboratory at the State University of New York Health Center at Brooklyn*), por ter recolhido e disponibilizado o dataset EEG usado neste estudo.

Ao David M. J. Tax, autor da toolbox pública `dd_tools` usada no processo de classificação.

E a todos aqueles, que de alguma forma, colaboraram na realização desta tese.

palavras-chave

biometria, autenticação, electroencefalograma, potenciais visuais evocados, occipital, classificação, OCC.

resumo

Este documento estuda a possibilidade de usar sinais electroencefalográficos (EEG) como característica biométrica de um indivíduo para o processo de autenticação.

As respostas cerebrais, que originaram os EEGs considerados neste estudo, foram gravadas durante a estimulação visual dos indivíduos, levando à ocorrência um tipo de actividade cerebral muito particular designada por Potencial Visual Evocado (VEP). No estudo apresentado, apenas os sinais EEG adquiridos por 8 eléctrodos, situados na zona occipital do cortex cerebral, foram considerados.

Após a aquisição dos EEGs é iniciada uma sequência de processos que visam extrair um modelo matemático que permita identificar singularmente cada indivíduo. Depois de extraídas as características biométricas de cada indivíduo, estas são usadas para treinar e testar o classificador respectivo. Neste estudo será considerado um classificador por cada pessoa a autenticar.

Para classificação da informação extraída dos EEGs, dois tipos de *one class classifiers* (OCC) são apresentados, o k-Nearest Neighbor Data Description (KNNDD) e o *Support Vector Data Description* (SVDD). Este tipo de classificação tem a particularidade de que, os classificadores só precisam de ser treinados com objectos da classe a reconhecer como verdadeira, a classe alvo.

Os resultados obtidos, após testar cada classificador com os modelos matemáticos extraídos de cada indivíduo, mostraram que de facto existe informação, presente nas respostas EEG da zona occipital do cortex cerebral, que pode ser adoptada para conduzir a autenticação biométrica de pessoas com uma taxa de sucesso consideravelmente boa.

keywords

biometric, authentication, electroencephalogram, visual evoked potencial ,one class classification

abstract

This document studies the suitability of brain activity signals, namely electroencephalogram signals (EEG), as raw material for conducting biometric authentication of individuals.

Brain responses were extracted in particular scenarios, namely with visual stimulation leading to biological brain responses known as visual evoked potentials. In our study we evaluated a novel method, using only 8 occipital electrodes to measure and extract information about the subjects for further use as their biometric information.

To classify the features obtained from each individual we used a one-class classifier per subject. These classifiers have the particularity that they are trained only with its target class features, which is the correct procedure to apply in a biometric authentication scenario. Two types of one class classifiers were tested, K-Nearest Neighbor Data Description (kNNDD) and Support Vector Data Description (SVDD).

After testing the individual classifiers with all subjects extracted features, the results showed that in fact there is information about their brain responses to visual stimuli that can be used for conducting biometric authentications with high correctness.

Índice

1 - Introdução	3
2 - Contexto	7
2.1 - Autenticação Biométrica	7
2.2 - Electroencefalograma (EEG)	13
2.2.1 - Actividade EEG	13
2.3 - Potenciais Evocados.....	16
2.4 - Interface Cérebro-Computador (<i>Brain Computer Interface</i> , BCI)	17
2.5 - <i>One Class Classification</i> (OCC)	19
2.5.1 – Métodos OCC.....	20
2.5.2 - Support Vector Data Description (SVDD).....	23
2.5.3 - K – Nearest Neighbor Data Description (KNDD).....	22
2.5.4 - Combinação de vários classificadores.....	24
3 – O Estado da Arte	25
4 - Autenticação Biométrica com EEG	29
4.1 – Descrição do <i>dataset</i>	32
4.1.1 – Estrutura de dados usada para representar o <i>dataset</i>	36
4.2 - Processamento do sinal EEG e extracção das suas características biométricas.....	37
4.2.1 - Ajuste da média do evento para zero.....	37
4.2.2 - Rejeição de eventos com artefactos.....	37
4.2.3 - Extracção da banda de frequências <i>Gama</i> (30-50 Hz)	39
4.2.4 - Composição dos sinais VEP extraídos	41
4.2.5 - Cálculo da energia do sinal para cada evento.....	42
4.2.6 - Normalização da energia do sinal	42
4.3 - Classificação e Análise das Características Extraídas	43
4.3.1 – Análise Visual das Características Extraídas.....	43
4.3.2 – Treino e Teste dos OCCs com os Vectors de Características Extraídos	45
5 – Resultados e discussão	48
5.1 - Receiver Operating Characteristic curve (curva ROC)	48
5.2 – Resultados Gerais.....	50
5.3 – Resultados dos classificadores individuais.....	54
6 - Conclusão	59
7 - Referências Bibliográficas	61

Figura 1 - Diferenças de arquitectura entre identificação e autenticação	8
Figura 2 - Arquitectura genérica de um sistema de autenticação biométrica	8
Figura 3 – impressão digital e os seus pontos de minúcia.....	9
Figura 4 – Íris e os aneis que a constituem.....	9
Figura 5 – Retina os seus vasos sanguíneos.....	10
Figura 6 – Geometria da mão considerada.....	10
Figura 7 – Face e a sua estrutura óssea considerada.....	11
Figura 8 – Assinatura considerada para autenticação.....	11
Figura 9 – características biométricas extraídas de um sinal de voz	12
Figura 10 – Sinais EEG adquiridos por 11 eléctrodos.....	12
Figura 11 – Exemplo de um sinal EEG (1seg).....	13
Figura 12 – Frequências EEG Delta (1 Seg.).....	14
Figura 13 – Frequências EEG Teta (1 Seg.).....	14
Figura 14 – Frequências EEG Alfa (1seg)	14
Figura 15 – Frequências EEG Beta (1 Seg.).....	15
Figura 16 – Frequências EEG <i>Gama</i> (1 Seg.).....	15
Figura 18 – Arquitectura genérica de um BCI	18
Figura 19 - Diagrama dos OCC combinados, OR e AND.....	24
Figura 20 – Método experimental aplicado aos sinais VEPs adquiridos.	31
Figura 21 - Colocação espacial dos eléctrodos (61 activos + 3 Ref.) disponíveis pelo <i>dataset</i> e os 8 eléctrodos occipitais.	33
Figura 22- Seis imagens do conjunto de Snodgrass & Vanderwart.....	33
Figura 23- Experiência visual a decorrer durante a aquisição dos sinais EEG.....	34
Figura 24- Amplitude dos sinais EEGs, captados por 64 canais, durante a visualização de uma imagem.....	35
Figura 25 - Evento com ocorrência de artefactos.....	38
Figura 26 - Resposta em magnitude e frequência do filtro butterworth de ordem 10 aplicado.	39
Figura 27 – EEG e o seu espectro de potência, antes de aplicado o filtro Butterworth	40
Figura 28 – EEG e o seu espectro de potência, depois de aplicado o filtro Butterworth	40
Figura 29 – Os 36 sinais VEP compostos : 8 sinais VEP + 28 sinais resultantes das diferenças entre os pares de sinais.	41
Figura 31- Exemplo de um vector de características extraído (energia normalizada dos 36 sinais).....	42
Figura 32- vectores de características extraídos de 10 pessoas diferentes.....	44
Figura 33 - Vectores usados para treino.....	47
Figura 34 - Vectores de teste simples.....	47
Figura 35 - Vectores de teste combinados dois a dois.....	47

1 Introdução

O universo digital tem vindo a apresentar nas últimas décadas um aumento exponencial na área das informações, tornando-se assim necessário a implementação de meios e tecnologias de acesso cada vez mais seguras. Um dos principais aspectos a ter em consideração, para garantir a segurança no acesso à informação, é a identificação e a autenticação biométrica de utilizadores.

A biometria é a ciência que estuda a possibilidade de usar características, fisiológicas ou não, que permitam identificar singularmente cada pessoa. A autenticação biométrica consiste na comparação de um conjunto de características biométricas de um indivíduo com informação previamente recolhida sobre o mesmo (template), de modo a verificar a sua identidade.

Os métodos de autenticação biométrica actuais baseiam-se na análise de características estáticas com descrição gráfica (impressão digital, imagem da íris, etc.) ou de características dinâmicas (dinâmica de escrita num teclado, timbre da voz, etc.), mas sem que o sujeito autenticado responda a estímulos sensoriais. Por este facto, a falsificação de características biométricas pode ser facilitada. Este problema pode ser evitado através da autenticação biométrica de indivíduos usando as suas respostas a estímulos exteriores, admitindo que os estímulos, mas não as suas respostas, podem variar entre diferentes ocasiões em que é feita a operação de autenticação.

Nesta dissertação pretende-se estudar a possibilidade de efectuar o processo de autenticação biométrica de indivíduos usando informação latente na sua actividade cerebral EEG (electroencefalograma).

Os sinais EEG são impossíveis de replicar por outra pessoa, uma vez que reflectem um processo electro-fisiológico que ocorre nos milhões de neurónios que constituem o cérebro humano. É a forma como estes neurónios comunicam entre si, que define a personalidade de uma pessoa, assim como a sua interpretação da realidade que a rodeia.

Como os sinais EEG não reflectem apenas um tipo de actividade isolado, mas sim a soma de todas as actividades cerebrais a ocorrer no mesmo instante de tempo, a sua interpretação acaba por ser bastante complexa. Assim, para tornar a informação EEG a avaliar mais simples e constante, focamos a nossa investigação apenas em sinais EEG resultantes do fenómeno fisiológico que ocorre na zona occipital do cortex cérebro quando um indivíduo visualiza uma imagem, fenómeno este também conhecido por potencial visual evocado (*Visual Evoked Potential*, VEP) [10].

Para que a informação a retirar dos VEP de cada pessoa possa ser considerada como sua característica biométrica, esta deve obedecer a quatro aspectos fundamentais [1]:

- **Universalidade:** possibilidade de ser utilizado por todas as pessoas.
- **Unicidade:** capacidade de distinguir diferentes pessoas com uma probabilidade de erro bastante reduzida ou nula.
- **Constância:** as características biométricas dos indivíduos devem permanecer inalteráveis durante um período razoável de tempo (meses, anos).
- **Colectabilidade:** as características biométricas devem ser de fácil aquisição para que tal não provoque desconforto ao indivíduo durante a sua aquisição.

Referente ao primeiro aspecto (universalidade), acredita-se que apenas uma pequena percentagem da população não possa usar este procedimento para autenticação biométrica. Como a informação latente nos sinais EEG a considerar é despoletada por estímulos visuais, as pessoas com deficiências visuais não podem naturalmente usar este tipo de sistema.

Considerando o segundo aspecto (unicidade), o estudo foi efectuado sobre uma população de 70 pessoas, cujos sinais EEG foram gravados enquanto estes visualizavam imagens. Embora, o número de pessoas considerado neste estudo seja limitado, este é bastante significativo e deverá reflectir a performance do sistema para populações maiores, logo ao conseguir extrair informação de uma pessoa que a permita distinguir dos outros 69 indivíduos, espera-se alcançar o mesmo para uma população à escala global.

Em relação ao terceiro aspecto (constância), o estudo efectuado não é objectivo e deverá ser complementado por outros estudos. No estudo considerado, os EEGs de cada indivíduo foram gravados com intervalos de tempo entre estímulos bastante curtos (5 segundos). Desta forma, os sinais EEG gravados não reflectem possíveis alterações ao longo do tempo, tais como a fadiga, o stress, medicação, etc.. No entanto, embora não reflecta possíveis variações diárias, o estudo efectuado mostra que a informação é bastante constante para cada indivíduo considerando VEP adquiridos em intervalos de tempo curtos.

Considerando o quarto aspecto (colectabilidade), a tecnologia necessária para a recolha deste tipo de informação apresenta à partida um grave problema de usabilidade. Como os sinais EEG possuem amplitudes muito baixas (μV), para a sua recolha é necessário o uso de eléctrodos com grande poder de amplificação. Para além do facto destes eléctrodos terem de ser colocados em posições exactas no escalpe do indivíduo, estes também, devido ao seu poder de amplificação, captam as mais variadas fontes de ruído electromagnético presentes no espaço que o rodeia. Daí ser necessário fazer a recolha

destes sinais em locais com algum tipo de isolamento eléctrico. Espera-se que num futuro próximo esta barreira desapareça com a chegada de novas técnicas de aquisição. A referir que no estudo realizado foi aplicado algum esforço na tentativa de aumentar a usabilidade e colectabilidade deste tipo de sistema. Para tal, várias simulações foram realizadas na tentativa de conseguir obter os melhores resultados usando o menor número possível de eléctrodos.

O estudo apresentado neste documento divide-se em duas linhas de acção que se pretendem complementar.

De início, os esforços realizados visaram a identificação de informação, presente nos sinais EEG considerados, que possa ser usada como característica biométrica de indivíduos, i.e., deve representar cada pessoa singularmente. Para o estudo realizado foi considerado um *dataset* público com vários sinais EEG gravados durante a estimulação visual de 70 pessoas diferentes.

Depois os esforços foram direccionados para a classificação da informação extraída dos sinais EEG de cada indivíduo de forma a atribuir a estes a classe “Verdadeiro” ou “Falso”. Para o processo de classificação optou-se por um cenário de *One Class Classification* (OCC) [2] e usaram-se dois tipos concretos de classificadores, o k-Nearest Neighbour (kNN) e o Support Vector Machine (SVM). Estes, quando adaptados ao um cenário OCC, correspondem aos OCC (*One Class Classifiers*) k-Nearest Neighbour Data Description (KNDD) e Support Vector Data Description (SVDD) [2].

Desta forma, para o sistema de classificação considerado, cada indivíduo terá um classificador previamente treinado para o reconhecer, logo, quando o indivíduo X se autenticar perante o sistema, este irá avaliar a informação recolhida do indivíduo com o classificador do indivíduo X de modo a verificar se essa informação pertencente ou não ao indivíduo X.

A opção de ter usado OCC deveu-se a dois aspectos fundamentais e intrínsecos ao conceito de autenticação biométrica: (i) o facto de que estes tipos de classificadores só precisarem de ser treinados com os objectos da classe a reconhecer como verdadeira (classe alvo) e (ii) o facto de só oferecerem dois tipos de saída (Verdadeiro ou Falso).

Após treinar o classificador de cada indivíduo com informação recolhida de uma parte dos seus VEP, foram usados os restantes VEP de todos os indivíduos, incluindo do próprio, para os testar. Desta forma obtiveram-se, por cada classificador, a taxa de aceitação do seu dono (verdadeiros positivos) e a taxa de aceitação dos outros indivíduos (falsos positivos). Este processo de classificação foi repetido fazendo variar alguns parâmetros ajustáveis no sistema de autenticação adoptado.

Os resultados obtidos demonstraram que, de facto, existe informação pessoal latente no sinal EEG de um indivíduo, enquanto este visualiza um estímulo, que pode ser usada como sua característica biométrica, i.e., permite autenticá-lo singularmente com uma taxa de verdadeiros positivos e falsos positivos bastante aceitável.¹

Este documento encontra-se estruturado em 3 secções principais. A primeira secção consiste na descrição dos conceitos teóricos que se encontram relacionados com o estudo efectuado. Na segunda secção é apresentado o método adoptado para extracção e classificação das características biométricas latentes nos sinais EEG dos indivíduos considerados. Por último, é efectuada a análise sobre o sucesso obtido após a classificação dos indivíduos com as características biométricas previamente extraídas destes.

¹ O sistema de autenticação descrito neste documento foi submetido para publicação na conferência IEEE Second International Conference on Biometrics: Theory, Applications and Systems; O resultado será conhecido apenas a 25 de Julho de 2008.

2 Contexto

2.1 Autenticação Biométrica

A identidade biométrica pode ser definida como sendo a "característica física, única e mensurável, de uma pessoa". Todas as pessoas possuem algumas dessas características, através das quais podem ser singularmente identificadas, como por exemplo, a impressão digital, a retina, a face, a geometria da mão e o DNA, entre outras.

Relacionado com a biometria existem dois aspectos a considerar, a identificação e a autenticação de indivíduos(ver Figura 1). Enquanto que no processo de autenticação as características biométricas dos indivíduo são apenas comparadas com o template das suas próprias características, existentes na base de dados, para verificar se a pessoa é realmente quem diz ser, no processo de identificação biométrica as características biométricas da pessoa são comparadas com todos os templates existentes na base de dados e a pessoa é identificada como sendo aquela cujas características possui mais semelhanças com um dos *templates* armazenados.

O processo de autenticação biométrica divide-se em duas fases: (ver Figura 2)

1. **Registo do utilizador no sistema:** captura-se as características biométricas do utilizador, que posteriormente serão convertidas num modelo que as representa matematicamente.
2. **Autenticação do utilizador pelo sistema:** o utilizador apresenta as suas características biométricas, que são comparadas e validadas com o modelo armazenado anteriormente.

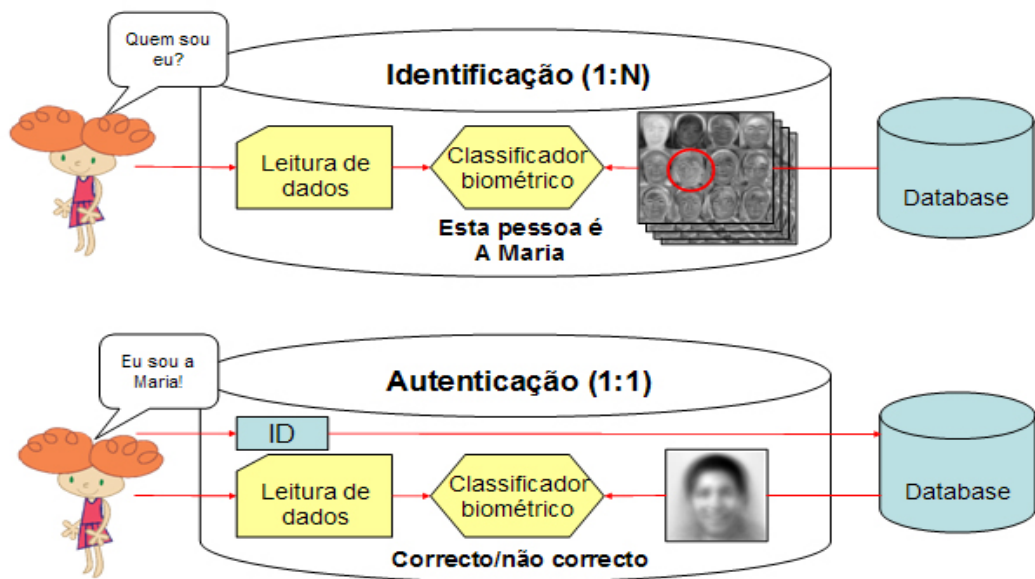


Figura 1 - Diferenças de arquitectura entre identificação e autenticação

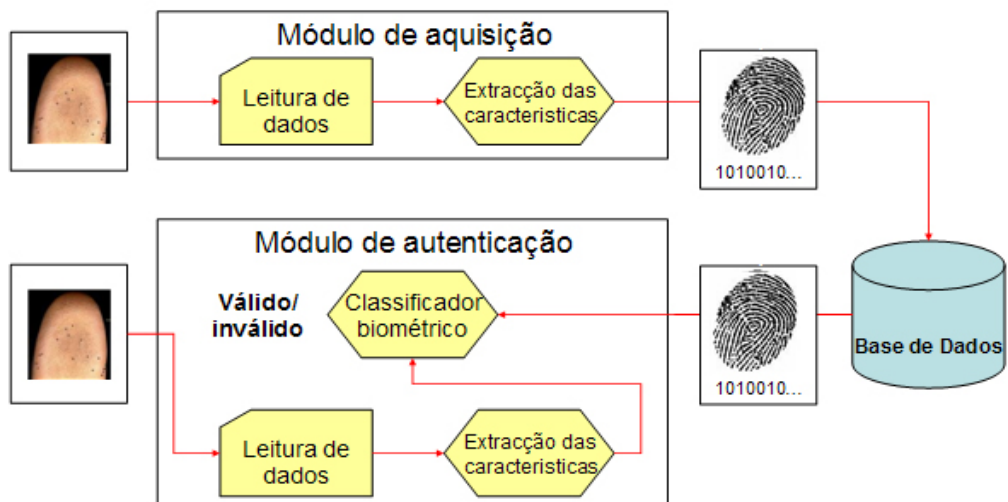


Figura 2 - Arquitectura genérica de um sistema de autenticação biométrica

Hoje em dia são inúmeras as tecnologias biométricas existentes. Passo a enumerar as mais utilizadas e a descrever resumidamente em que consiste cada uma destas.

1. Impressão Digital

A impressão digital é a técnica biométrica mais usada na actualidade, esta é fisiologicamente composta por vários sulcos, que, na sua formação apresentam algumas características físicas, chamadas de pontos de minúcias.

Cada um desses pontos possui características únicas que podem ser medidas. Ao compararmos duas impressões digitais podemos determinar seguramente, baseados nos pontos de minúcias, a quem pertencem. Na actualidade, estes leitores biométricos são capazes de identificar mais de 40 minúcias numa impressão digital [27,28].



Figura 3 – impressão digital e os seus pontos de minúcia

2. Íris

Baseada nos anéis coloridos do tecido que circunda a pupila, é considerada a menos intrusiva das tecnologias que envolvem o uso dos olhos para identificação, pois não necessita de um contacto muito próximo com o dispositivo de leitura, como no caso da retina. Outro factor que agrada aos utilizadores é o facto de não ser necessário retirar os óculos para fazer a leitura da íris [28].



Figura 4 – Íris e os aneis que a constituem

3. Retina

A biometria da retina é baseada na análise da camada dos vasos sanguíneos existentes nos olhos. Para isto utiliza-se uma luz de baixa intensidade, que passa pela superfície para encontrar os padrões singulares da retina.

Esta é uma técnica de grande precisão e praticamente impossível de ser adulterada devido à forte relação com os sinais vitais humanos. Não é normalmente bem aceite pelos utilizadores por requerer que estes olhem num visor e focalize um determinado ponto, o que apresenta alguma dificuldade se o utilizador usar óculos [28].



Figura 5 – Retina os seus vasos sanguíneos

4. Geometria da Mão

Os dispositivos biométricos da mão são rápidos, de fácil operação e baseiam-se nas medidas da mão do utilizador. São ideais para ambientes onde o acesso a áreas restritas necessita de ser rápido e seguro como, por exemplo, no controle de acesso de funcionários de uma empresa [28].




Figura 6 – Geometria da mão considerada

5. Face

A autenticação é realizada através de uma câmara digital, que captura as características da face e da sua estrutura óssea. No entanto alguns factores, tais como o corte de cabelo ou uso de óculos, podem dificultar o processo de reconhecimento.




Figura 7 – Face e a sua estrutura óssea considerada

6. Assinatura

Este processo de autenticação consiste em analisar características, tais como a forma, velocidade e pressão de uma assinatura. Os utilizadores desta tecnologia identificam-se bastante com o processo, por já ser um meio de autenticação habitual [28].



Figura 8 – Assinatura considerada para autenticação

7. Voz

A autenticação através da voz baseia-se no reconhecimento das características vocais de uma pessoa, quando esta pronuncia um determinado som. Estas características variam de acordo com a fisionomia de cada pessoa, tais como a boca, a traqueia, cavidades nasais entre outras.

A maior vantagem na aplicação desta tecnologia biométrica consiste no facto do hardware (microfone) envolvido na aquisição destas características ser bastante barato e acessível ao cidadão comum [28].




Figura 9 – características biométricas extraídas de um sinal de voz

8. Actividade cerebral EEG

Neste documento é proposto um novo método de autenticação biométrica baseado na extracção de características do sinal EEG (electroencefalograma) de um indivíduo, durante o período em que este é estimulado visualmente por imagens.

Esta tecnologia apresenta, à partida, um grave problema de usabilidade e colectabilidade, uma vez que será necessário a colocação de eléctrodos no escalpe do indivíduo sempre que este se sujeitar ao processo de autenticação. Apesar deste inconveniente, como os resultados da aplicação desta tecnologia foram satisfatórios, poderá se justificar a sua implementação num futuro próximo, uma vez que é a única tecnologia biométrica em que a informação singular do indivíduo resulta da sua reacção (cerebral) a um estímulo exterior.




Figura 10 – Sinais EEG adquiridos por 11 eléctrodos

2.2 Electroencefalograma (EEG)

O eletroencefalograma (EEG) consiste na captação da actividade bio-eléctrica do cérebro através de eléctrodos colocados no escalpe de um indivíduo. O princípio básico de obtenção dos sinais electroencefalográficos é a amplificação dos sinais eléctricos captados no escalpe, por meio de potentes circuitos amplificadores, chamados de amplificadores diferenciais. Estes circuitos são capazes de amplificar diferenças de potencial entre dois pontos do escalpe, um de maior e outro de menor voltagem.

Um EEG demonstra que os sinais eléctricos não são continuamente produzidos pelo cérebro, mas surgem em instantes curtos e regulares. Este fenómeno fisiológico produz um padrão que se manifesta numa série de ondas sinusoidais rítmicas, que representam a actividade cerebral numa determinada zona do cérebro em função do tempo.

Verifica-se também que a actividade cerebral varia de acordo com as tarefas a serem realizadas pelo cérebro, por exemplo, a actividade cerebral de um indivíduo que está num estado de sonolência produz ondas sinusoidais grandes e lentas, enquanto que actividades físicas ou pensamentos profundos produzem ondas de frequência mais alta.

2.2.1 Actividade EEG

Um sinal EEG é composto por várias ondas sinusoidais resultantes da actividade bio-eléctrica do cérebro. Existem cinco tipos cientificamente reconhecidos de actividade sinusoidal rítmica no sinal EEG (Delta δ , Teta θ , Alfa α , Beta β e *Gama* γ) [3]. De seguida, serão apresentados estes tipos de actividade sinusoidal rítmica EEG e descritas as características associadas a cada uma destas bandas de frequências.




Figura 11 – Exemplo de um sinal EEG (1seg)

1. Frequências Delta (0-4 Hz)

Encontram-se quase sempre associadas a um estado de consciência muito interiorizada, sendo mais frequente nos bebés. Aparecem, também, durante o sono profundo nas suas fases 3 e 4.




Figura 12 – Frequências EEG Delta (1 Seg.)

2. Frequências Teta (4-8 Hz)

Estas frequências são indicadoras de um estado de “não vigília”, mais frequentes em crianças e adolescentes. Podem ser observadas durante estados de hipnose, transe e sono leve.




Figura 13 – Frequências EEG Teta (1 Seg.)

3. Frequências Alfa (8-12 Hz).

Estas frequências são características de um estado relaxado mas, ao mesmo tempo, de consciência alerta, e são mais facilmente detectadas quando o sujeito se encontra de olhos fechados. A sua actividade é mais incidente sobre a zona do córtex occipital (visual).




Figura 14 – Frequências EEG Alfa (1seg)

Dentro dos ritmos Alfa existe uma variante de frequências a que se designaram ritmos mu (10-12 Hz). Estes ritmos encontram-se directamente relacionados com a intenção de movimento por parte do sujeito e, ao contrário das restantes frequências Alfa, estes são mais facilmente detectáveis na zona do córtex motor (central parietal).

4. Frequências Beta (12-30 Hz).

As frequências Beta de baixa amplitude encontram-se relacionadas com um estado de concentração activo ou de ansiedade. As frequências Beta de maior amplitude estão associadas com algumas patologias ou efeitos de drogas, especialmente benzodiazepinas.




Figura 15 – Frequências EEG Beta (1 Seg.)

5. Frequências Gama (30-60 Hz).

Os ritmos *Gama* aparecem sempre relacionados com um estado de actividade mental bastante elevada [4], incluindo cognição, percepção, resolução de problemas, medo e consciência activa [5], [6], [7] e por isso foram estes os ritmos considerados neste estudo. Estes são mais relevantes na zona occipital do córtex cerebral.




Figura 16 – Frequências EEG Gama (1 Seg.)

2.3 Potenciais Evocados (EPs)

Os potenciais evocados (*Evoked Potentials*, EPs) podem ser definidos como sendo as respostas electro-fisiológicas do córtex cerebral a estímulos sensoriais externos [9].

Os EPs considerados nesta dissertação são aqueles que resultam da reacção cerebral do indivíduo durante a sua estimulação visual através de uma série de imagens. Estes EPs denominam-se por potenciais visuais evocados (*Visual Evoked Potential*, VEP) [10,11] e são mais facilmente detectados na zona do córtex cerebral e banda de frequências relacionadas com o tipo de potencial evocado.

Existem vários tipos de paradigmas relacionados com os potenciais visuais evocados em indivíduos [29]. Neste estudo, serão usados os VEPs pertencentes ao paradigma que constitui a categoria “*Short latency visual evoked potential*”. Neste tipo de paradigma, o potencial é evocado apresentando ao indivíduo um estímulo visual com uma duração bastante curta (300 - 500 ms). Estes tipos de VEPs ocorrem com maior incidência na zona occipital do córtex cerebral e na banda de frequências *Gama*, que se encontra directamente relacionada com o processo de percepção, memória e cognição [4,5]. A escolha deste tipo de paradigma deve-se ao facto de que este não precisa de treino prévio por parte do utilizador, uma vez que apenas a sua resposta imediata ao estímulo é considerada.

2.4 Interface Cérebro-Computador (*Brain Computer Interface, BCI*)

Um sistema BCI (*Brain Computer Interface*) é um sistema que recebe e processa um sinal EEG, de forma a criar um canal de comunicação directo entre o cérebro de um indivíduo e um computador, isto é, permite a um utilizador controlar ou interagir com uma aplicação no computador, através da sua actividade cerebral. O conceito de BCI é aqui apresentado uma vez que, na realidade, o nosso sistema de autenticação a implementar não é mais que um BCI cuja principal funcionalidade é extrair/classificar informação biométrica originada pelos sinais EEG de indivíduos.

O canal de comunicação oferecido por um BCI possui várias potencialidades, e é na actualidade aplicado em diversas áreas científicas, tais como:

- Aplicações na área de bio-engenharia: dispositivos de assistência a pessoas com deficiências motoras.
- Monitorização de indivíduos para detecção de patologias: perturbações de sono, doenças neuronais, etc.
- Pesquisa na área da neurociência: oferece métodos para correlacionar, em tempo real, o comportamento de um indivíduo em diversas situações.
- Interação humano-computador: oferece uma forma de interface entre o humano e uma tarefa a ser realizada no computador.

O elemento central em cada BCI é o algoritmo responsável por efectuar a conversão do sinal EEG recebido, num output (sinal de controle) relevante para a aplicação em questão.

A arquitectura mais comum de um BCI é a seguinte:

1. **Aquisição do sinal:** Os sinais EEG são recebidos do cérebro, através de um método invasivo ou não-invasivo, amplificado e digitalizado a uma determinada taxa de amostragem.
2. **Processamento do sinal:** É eliminado o ruído do sinal recebido e processado de forma a extrair as características do sinal que interessam para a aplicação em questão.
3. **Classificação do sinal processado:** Após a extracção das características do sinal, estas são classificadas nos vários sinais de controlo que a aplicação oferece.
4. **Interacção com o computador:** Depois de serem classificados os sinais, estes são usados pelo algoritmo apropriado para produzir a interacção pretendida na aplicação.

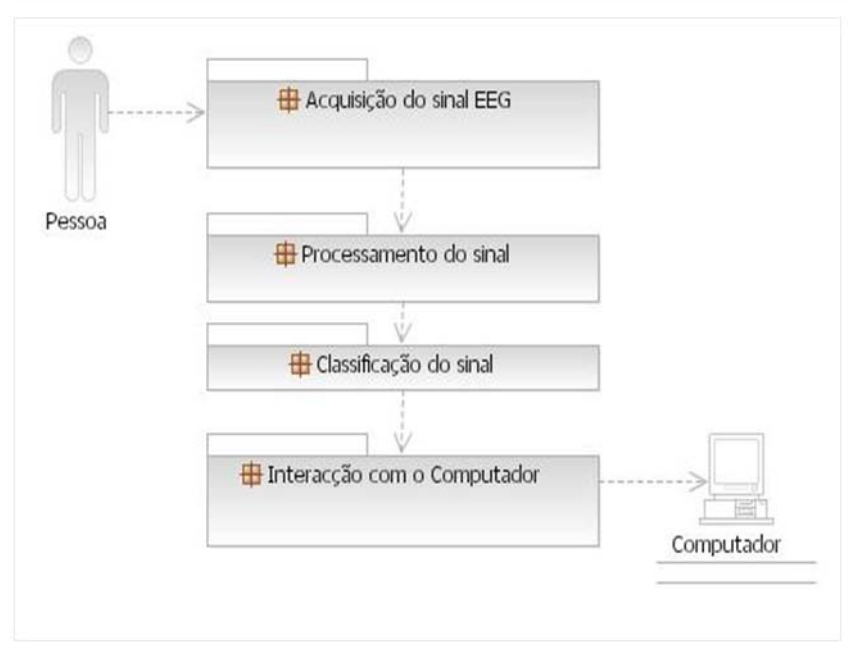


Figura 17 – Arquitectura genérica de um BCI

2.5 One Class Classification (OCC)

O conceito de classificação de uma só classe (*One Class Classification*, OCC) [2] é aqui introduzido, pois este foi o tipo de classificação adoptada para avaliar as características extraídas de cada indivíduo, como pertencentes ou não a estes (Verdadeiro/Falso).

O problema de classificação de uma classe é na realidade um problema onde se pretende distinguir duas classes, a classe alvo e a classe exterior. A classe alvo é a classe que o classificador deve reconhecer e classificar como verdadeira. Note-se que num cenário do tipo OCC apenas objectos da classe alvo são usados para treino do classificador. A classe exterior, ou classe falsa, aparece só durante a fase de teste do classificador e pode ser considerada como sendo uma outra qualquer classe que não possui as mesmas características da classe alvo, ou seja, os seus valores, do ponto de vista do classificador, são bastante diferentes dos que apresentam os objectos para os quais este foi treinado.

A classificação de uma classe difere de outros tipos convencionais de classificações num aspecto fundamental, neste tipo de classificação apenas os objectos da classe alvo são conhecidos a priori, desta forma pretende-se que durante o treino do classificador com os objectos da classe alvo, se estabeleçam fronteiras delimitadoras que permitam aceitar o máximo de objectos da classe alvo minimizando a probabilidade de aceitar objectos da classe exterior.

Tabela 1 - Possíveis classificações de um OCC

	Objecto da classe alvo	Objecto da classe exterior
Classificado como classe alvo	Correcto (verdadeiro positivo)	Incorrecto (falso positivo)
Classificado como classe Exterior	Incorrecto (falso negativo)	Correcto (verdadeiro negativo)

2.5.1 Métodos OCC

Em todos os métodos OCC dois tipos de elementos distintos podem ser identificados [2]. O primeiro elemento é a medida da distância $d(z)$ ou probabilidade $p(z)$, de um objecto z em relação à classe alvo representada pelo conjunto de treino X_{tr} . O segundo elemento é o limiar d ou p aplicado sobre esta distância ou probabilidade entre objectos. Assim, novos objectos são aceites quando a sua distância $d(z)$ à classe alvo é menor que o limiar d , ou quando a sua probabilidade $p(z)$ é maior que o limiar p . É atribuído a um objecto à classe alvo quando:

$$f(z) = d(z) < d \vee f(z) = p(z) > p$$

Vários métodos têm sido apresentados para resolver problemas de OCC. No entanto apenas três métodos têm sido relevantes neste tipo de classificação: estimação de densidade de probabilidade, fronteiras e reconstrução.

1. Método de estimação de densidade de probabilidade

Este método de classificação é baseado na estimativa da densidade de probabilidade do conjunto de treino. Desta forma, todos os objectos que durante a sua classificação não excederem um limiar de densidade de probabilidade serão considerados como exteriores e serão rejeitados pelo classificador. Três tipos de classificação baseados neste método são *Gaussian model*, *mixture of Gaussians* e *Parzen density estimators* [2].

2. Método de reconstrução

Neste método de classificação, é usado o conhecimento a priori sobre os objectos para gerar e escolher um modelo matemático que representará estes objectos. Através da aplicação de métodos de reconstrução, é assumido que os objectos exteriores não se aproximam dos objectos descritos pelo modelo pois o seu erro de reconstrução deverá ser elevado. *k-mean clustering*, *self-organizing maps* e *PCA* são alguns dos tipos de classificadores baseados nestes métodos [2]

3. Método de fronteiras ou limites

Nos métodos de fronteiras não é necessário estimar a densidade de probabilidade de todos os objectos, mas sim estimar limites fechados ou fronteiras em torno do conjunto de objectos pertencentes à classe alvo, de forma ao classificador maximizar o reconhecimento dos objectos alvo e a discriminar possíveis objectos exteriores.

Este método possui a vantagem de que não é necessário um grande número de objectos pertencentes à classe alvo para que a sua descrição fique bem definida no classificador, uma vez que é baseado na distância entre objectos e não nas suas densidades de probabilidade.

Outra particularidade na aplicação do método de fronteiras é o facto de ser obrigatório definir um valor de fracção de rejeição (fr) sobre o conjunto de treino. O conjunto de treino é usado pelo classificador para delimitar as fronteiras da classe alvo, considerando que uma fracção fr destes objectos não representa a classe alvo. Assim, usando valores de fr mais elevados as fronteiras delimitadoras das duas classes serão mais restritas à classe alvo, resultando numa minimização de objectos exteriores aceites, enquanto que usando valores de fr mais baixos as fronteiras ficam menos restritas à classe alvo maximizando assim a probabilidade de objectos alvo aceites em posteriores classificações.

O *k nearest neighbour* (KNND) e *support vector data description* (SVDD) são alguns dos classificadores baseados no método das fronteiras mais usados [2] e serão considerados no sistema de autenticação adoptado neste estudo.

A razão de ter optado pelo uso do método das fronteiras, e não outro, baseia-se em dois aspectos fundamentais. O primeiro aspecto a considerar é o facto de este ser o método que exige menos amostras de objectos da classe alvo, para conseguir uma boa descrição do conjunto que a representa [2]. O segundo aspecto deve-se à possibilidade de definir um valor de fr que afecta directamente a restrição imposta à fronteira que delimita a classe alvo [2].

De seguida serão apresentados e discutidos os dois tipos de OCC (KNND e SVDD) considerados neste estudo para a classificação das características biométricas extraídas dos VEP de cada indivíduo. Como já referido, ambos os classificadores considerados usam o método das fronteiras para identificação dos objectos pertencentes a cada classe.

2.5.2 k-Nearest Neighbor Data Description (KNNDD)

O KNNDD é um classificador onde o processo de aprendizagem é baseado na analogia do vizinho mais próximo. Neste classificador, o conjunto de treino é formado por vectores n-dimensionais, onde cada elemento deste conjunto representa um ponto no espaço n-dimensional.

Para determinar a classe de um elemento que não pertença ao conjunto de treino, o classificador KNNDD procura os K elementos do conjunto de treino que estejam mais próximos deste elemento desconhecido, ou seja, que possuam a menor distância relativa a este.

Normalmente, como os objectos do conjunto de treino são n-dimensionais, uma hiper-esfera de n-dimensões é centrada sobre o objecto z a classificar, depois o seu volume é aumentado gradualmente até que esta englobe k objectos do conjunto de treino. De seguida a sua densidade local é calculada de acordo com a seguinte fórmula:

$$p_{NN}(z) = \frac{k/N}{V_k(\|z - NN_k^{tr}(z)\|)}$$

onde $NN_k(z)$ representa o k vizinho mais próximo do objecto z a classificar e V_k é o volume da hiper-esfera que engloba este objecto.

Desta forma um objecto z a classificar é aceite quando a sua densidade local é maior ou igual à do seu primeiro vizinho mais próximo no conjunto de treino.

$$f_{NN^{tr}}(z) = I \left(\frac{1/N}{V(\|z - NN^{tr}(z)\|)} \geq \frac{1/N}{V(\|NN^{tr}(z) - NN^{tr}(NN^{tr}(z))\|)} \right)$$

que é equivalente a:

$$f_{NN^{tr}}(z) = I \left(\frac{V(\|z - NN^{tr}(z)\|)}{V(\|NN^{tr}(z) - NN^{tr}(NN^{tr}(z))\|)} \leq 1 \right)$$

2.5.3 Support Vector Data Description (SVDD)

O classificador SVDD [2] é uma adaptação do classificador Support Vector Machine (SVM) a problemas de classificação com uma só classe.

Este classificador oferece a possibilidade de mapear objectos para um espaço com mais dimensões, sem que isso implique um aumento de custos computacionais extra. Desta forma, é possível obter descrições dos objectos a classificar mais detalhadas e flexíveis. Os custos computacionais reduzidos tornam-se evidentes, uma vez que os objectos num SVDD podem descritos por apenas uma pequena amostra dos seus objectos, os *support vectors*.

De inicio é definida uma hiper-esfera, com centro em a e raio R , que delimita uma fronteira em torno dos objectos pertencentes ao conjunto de treino X_{tr} . De seguida é definido, de forma análoga ao SVM, o erro estrutural

$$\mathcal{E}_{\text{struct}}(R, \mathbf{a}) = R^2$$

que é minimizado através da seguinte restrição:

$$\|\mathbf{x}_i - \mathbf{a}\|^2 \leq R^2, \quad \forall i$$

Posteriormente, após a computação da percentagem de objectos que serão considerados *support vectors* na fronteira de decisão entre classes alvo e exterior, multiplicadores de Lagrange serão aplicados e usados no cálculo da hiper-esfera com centro em a e limite de decisão ou raio R . O processo de classificação de outros objectos é baseado nos limites de decisão ou limiar, impostos pela hiper-esfera calculada com o conjunto de treino.

2.5.4 - Combinação de vários classificadores

Para além dos dois classificadores discutidos anteriormente, outros dois tipos de arquitectura de classificação foram usados para a autenticação biométrica dos indivíduos. Estas duas arquitecturas, designadas por OR e AND, resultaram da combinação “lógica” do KNNDD com o SVDD. Através da combinação destes dois classificadores pretende-se que a saída do classificador final fosse sempre uma função das saídas dos dois classificadores individuais. Desta forma, os resultados de cada classificador individual são complementados com os resultados do outro, esperando-se assim alcançar uma classificação mais correcta do que aquela obtida usando cada classificador isolado.

Na realização da operação lógica OR, a saída do OCC final é calculada através da média normalizada das saídas de cada OCC individual; desta forma, uma saída de valor baixo de um classificador pode ser compensada com uma saída de valor elevado do outro classificador, e vice-versa. Na realização da operação lógica AND, a saída do OCC final resulta da multiplicação normalizada das saídas dos OCC individuais, ou seja uma saída de valor baixo prevalece sempre sobre uma saída de valor elevado.




Figura 18 - Diagrama dos OCC combinados, OR e AND

3 – O Estado da Arte

Actualmente, as tecnologias de autenticação biométrica têm apresentado uma crescente acessibilidade, sendo já utilizadas em muitas empresas e instituições governamentais. As principais preocupações relativamente a esta tecnologia estão ligadas à segurança, à facilidade de implementação e ao tipo de biometria a adoptar. Apesar de, na área da biometria, muito ter sido apresentado e discutido, relativamente ao uso da actividade cerebral para este propósito pouco ainda se sabe.

De seguida serão apresentados trabalhos que ocorreram na história desta ciência, onde se discutiram e apresentaram resultados concretos relativos à viabilidade do uso da actividade cerebral como característica biométrica de um indivíduo.

Em 1999, Poulus *et al.* [12,13] propuseram um primeiro método que utilizava modelação auto-regressiva de sinais EEG e redes neuronais lineares para reconhecer um indivíduo como sendo distinto de outros indivíduos com um sucesso de 72-80%.

Em 2001, Paranjape *et al.* [14] propôs um método usando também modelação auto-regressiva dos sinais EEG com análises discriminatórias para identificar indivíduos, com uma classificação e precisão entre 49% a 85% de classificações correctas.

Ambos os métodos referidos usaram sinais EEG registados e gravados enquanto os sujeitos descansavam de olhos fechados ou abertos, e não em consequência das suas respostas resultantes a estímulos exteriores.

Em 2004, R. Palaniappan [15] propôs um novo método de identificação biométrica utilizando VEP e sinais EEG da banda *Gama*. No método apresentado, os sinais VEP são extraídos e gravados de 64 canais (61 activos + 3 referência), a 256 amostras por segundo, enquanto os sujeitos processam visualmente uma única imagem. De seguida, estes sinais VEP são filtrados para obter a sua banda *Gama* de frequências, entre os 30-50 Hz. Por último, é aplicado o teorema de equivalência tempo-frequência de Parseval, para se obter a energia espectral e é calculada a razão da energia da banda *Gama* em relação à energia total do EEG original.

A banda *Gama* de frequências, assim como o tipo de estímulos visuais, foram especificamente usados devido ao seu sucesso prévio no processo de classificação óptima entre alcoólicos e não-alcoólicos [25]. Além disso, esta banda de frequências tem sido relacionada com funções cerebrais mais complexas, tais como a percepção e a memória [5,6,7].

R. Palaniappan partiu do pressuposto que estas características, extraídas dos VEP, podem ser usadas para identificar indivíduos porque os níveis de acesso à percepção e à memória entre indivíduos são diferentes. Em acréscimo, estas diferenças são mais evidentes devido à pouca probabilidade dos indivíduos terem actividades cerebrais similares em todos os 61 canais.

Após extraídas as características dos VEP, pretendeu-se provar que estas eram passíveis de serem utilizadas para identificação biométrica dos indivíduos. Para verificar tal facto, R. Palaniappan fez uso da análise estatística ANOVA e t-test [30]. Os resultados obtidos através destes dois métodos de análise indicam que as características biométricas extraídas (razão da energia normalizada da banda *Gama* dos VEP) são estatisticamente iguais para cada indivíduo, independentemente do estímulo visual apresentado, e estatisticamente diferente entre indivíduos. Este estudo provou assim, que o método apresentado para extracção das características biométricas de um sinal EEG é válido.

Para o processo de identificação dos indivíduos através das suas características extraídas do sinal VEP foi utilizada uma rede neuronal treinada pelo algoritmo de *backpropagation* em vez de outros classificadores paramétricos ou outros tipos de arquitectura de redes neuronais.

Os resultados, percentagens correctas de identificação dos indivíduos, foram bastante satisfatórios, com cerca de 96% das classificações correctas ao identificar um indivíduo num universo de 20.

Em 2005, Ravi e Palaniappan publicaram dois artigos [16,17] propondo um novo processo de extracção de características biométricas dos VEP mas. Contudo, embora as “ferramentas” de extracção e classificação sejam diferentes, a característica biométrica extraída continua a ser a mesma (energia da banda *Gama* do VEP normalizada).

A única diferença, apresentada em relação ao artigo anterior, encontra-se no facto da extracção da banda *Gama* ser efectuada por um filtro elíptico e o processo de classificação por uma rede neuronal de Elman, cuja arquitectura é muito semelhante ao *backpropagation multilayer perceptron*. A percentagem de identificações correctas manteve-se também nos 95 %.

Ainda no mesmo ano, Ravi e Palaniappan publicaram um artigo [18] demonstrando que a classificação correcta das características extraídas dos VEP, aumenta se for aplicada, previamente, a computação da análise dos principais componentes (PCA) ao sinal VEP e posterior normalização, durante o processo de extracção das características referidas.

Para o processo de classificação das características extraídas foram usados dois algoritmos diferentes, o Simple Fuzzy ARTmap (SFA) e o K-Nearest Neighbour (kNN). As percentagens de classificações correctas, obtidas por cada um destes algoritmos, com e sem aplicação de PCA na extracção das características, foram respectivamente, 92.84% e 71.14 %, para o classificador SFAM e 92.04% e 70.88% para o classificador KNN.

Note-se que, embora o nome do artigo seja “*Leave-one-out Authentication of Persons*”, o processo biométrico neste efectuado é de identificação e não de autenticação.

Por último, em 2007, é publicado o único artigo [26] a apresentar um método para autenticação biométrica de indivíduos, através dos seus sinais EEG. Neste estudo foi feito o uso dos EEGs nas bandas Alfa e Beta, recolhidos, enquanto os sujeitos praticavam actividades mentais induzidas, tais como, movimentar as mãos ou imaginar uma letra. Na aquisição dos EEGs apenas 8 canais parietais foram considerados, dos quais resultavam 96 valores de características por vector (12 componentes de frequência por canal).

Após a extracção das características de cada actividade mental, eram aplicados os métodos das misturas de gaussianas e máximos a posteriori para classificação dos sujeitos. Os resultados destas classificações foram satisfatórios, mas não conclusivos devido ao número reduzido de pessoas usadas no estudo.

4 Autenticação Biométrica com EEG

Embora alguns dos trabalhos referidos anteriormente já tivessem abordado a possibilidade de usar os VEP como característica biométrica de um indivíduo, o estudo realizado nesta tese traz uma nova, melhorada e aprofundada abordagem sobre o processo de extração e classificação a aplicar sobre estas características, para autenticação biométrica de indivíduos.

Um dos principais objectivos a atingir com este estudo era alcançar um aumento significativo de usabilidade para futura aplicação destas características a sistemas de autenticação. No estudo realizado conseguiu-se reduzir o número de canais EEG usados para apenas 8 (occipitais) sem que para isso tivesse que ser comprometida a eficácia do sistema de autenticação considerado. Assim, com a diminuição do número de canais, de 61 para apenas 8, aumentou-se significativamente a usabilidade do sistema. A escolha dos 8 canais occipitais usados surgiu após várias experiências onde se correlacionou o número e localização dos canais usados com a eficácia dos resultados obtidos pelos classificadores.

Como já foi referido anteriormente, apenas a zona occipital do córtex cerebral foi considerada, pois é nesta zona que os VEP são mais evidentes [5,6,7]. Verificou-se que, com o uso de apenas 8 canais, é possível obter uma boa resolução sobre a informação biométrica presente nos VEP de cada indivíduo.

Outra abordagem introduzida nesta tese consiste no facto de usar estas características biométricas para autenticação de indivíduos e não para a sua identificação. Considera-se que o cenário de autenticação é mais adequado à aplicação destas características, uma vez que, num cenário de identificação estamos a lidar com um universo infinito de indivíduos, resultando no treino e classificação de infinitas classes por parte de um só classificador, o que acaba por ser um processo longo e com custos computacionais muito elevados. Num cenário de autenticação, cada classificador apenas precisa de conhecer as características biométricas do indivíduo a autenticar como verdadeiro, de forma a conseguir distinguir este de qualquer outro indivíduo.

Como já foi referido anteriormente, para o processo de classificação foram usados classificadores do tipo OCC, uma vez que são os que melhor se aplicam a um cenário de autenticação. Assim, para autenticar um indivíduo será usado o seu próprio classificador OCC, treinado previamente com as suas características biométricas, para que este só o reconheça a ele como verdadeiro e rejeite todos os demais.

Outro elemento inovador introduzido no trabalho realizado foi o estudo sobre a variação da eficácia do sistema de autenticação quando se usam para classificação a média de n características extraídas correspondentes à visualização de n estímulos, em vez de características isoladas. Com o uso da média de n estímulos em vez de estímulos isolados procurou-se atenuar as diferenças entre características extraídas de cada VEP, resultando assim em características com valores mais constantes.

O sistema de autenticação adoptado encontra-se resumido no diagrama da Figura 20. Para cada conjunto de sinais EEG gravados durante a apresentação de um estímulo (8 canais x 256 amostras) é realizado o procedimento descrito da Secção 4.2.

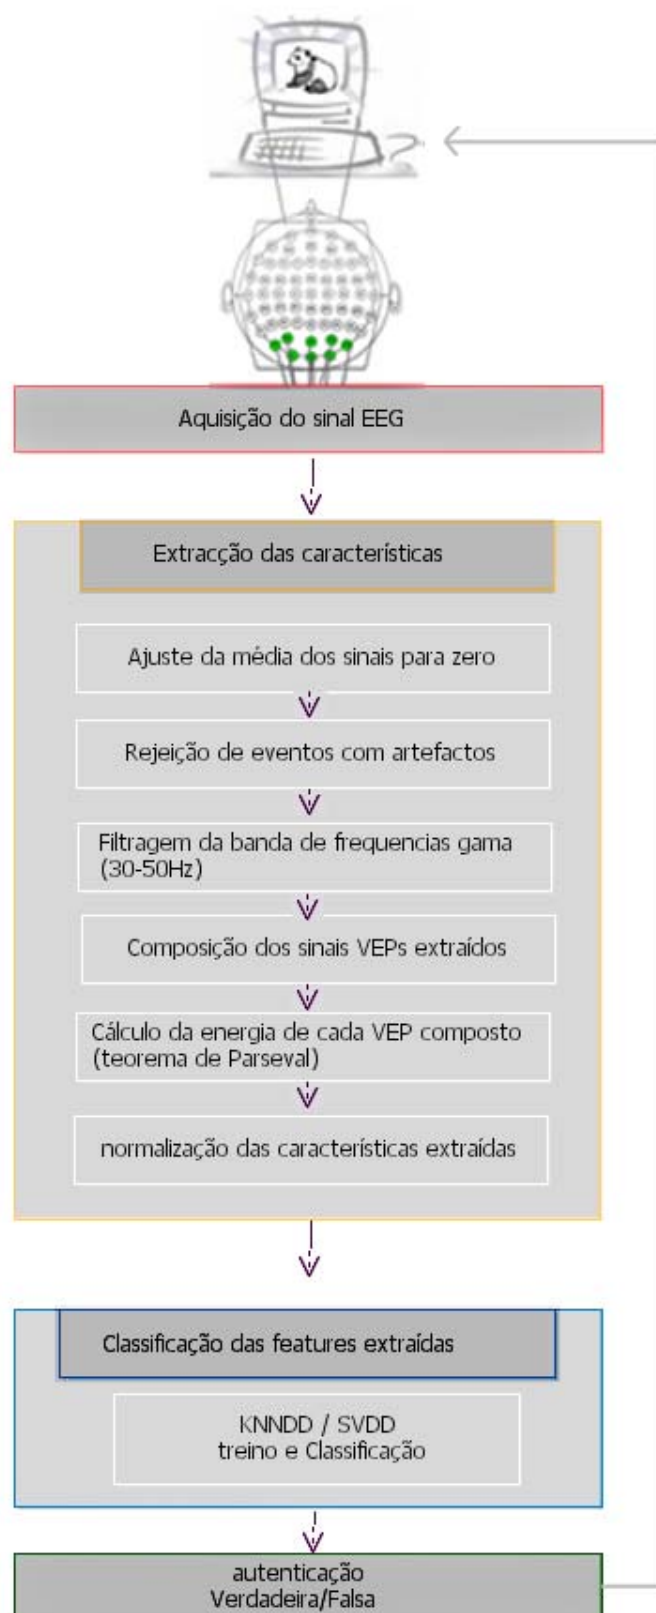


Figura 19 – Método experimental aplicado aos sinais VEPs adquiridos.

4.1 Descrição do *dataset*

Alguns dos artigos referidos no estado da arte [12,13,14,17,18] têm em comum o facto de usarem o mesmo *dataset*² EEG nos seus estudos. Este *dataset* foi igualmente usado no estudo apresentado nesta tese. O método de obtenção deste *dataset* foi o seguinte:

Foram gravados os sinais EEG de 70 indivíduos enquanto expostos a estímulos visuais. Cada indivíduo completou a visualização de um máximo de 45 estímulos, o que perfaz um total de 3150 VEP (45 estímulos X 70 indivíduos), gravados por 64 eléctrodos (61 activos + 3 referência) a 256 amostras por segundo e filtrados por hardware na banda de frequências (0.1 – 50 Hz).

Este *dataset* é na realidade um sub-*dataset* de uma experiência concebida para estudar as diferenças nos tempos de acesso à memória entre indivíduos alcoólicos e não-alcoólicos [25]. Neste estudo eram apresentados pares de imagens aos sujeitos, com intervalos de 5,1 segundos entre estas. Quando a segunda imagem era igual á primeira os indivíduos deviam pressionar um botão, caso contrário nada deveriam fazer.

No sub-*dataset* considerado neste estudo, apenas os sinais EEG adquiridos durante a apresentação da primeira imagem foram considerados, uma vez que a apresentação da segunda imagem implicava outro tipo de reacção fisiológica por parte do sujeito que poderia vir a interferir com o VEP. Assim, embora o *dataset* original ofereça os sinais EEGs de 120 pessoas, após a eliminação dos eventos em que ocorre a apresentação da segunda imagem, apenas 70 pessoas possuem o número mínimo de VEPs considerados neste estudo. Na experiência a realizar nesta tese, apenas 8 canais (occipitais), dos 64 disponíveis, foram considerados (ver Figura 21).

² *Dataset* usado encontra-se disponível no seguinte url: <http://kdd.ics.uci.edu/>.




Figura 20 - Colocação espacial dos electrodos (61 activos + 3 Ref.) disponíveis pelo *dataset* e os 8 electrodos occipitais, considerados no sistema de autenticação concebido (cinzento).

Os estímulos visuais apresentados aos indivíduos consistiam em imagens pertencentes ao conjunto de Snodgrass & Vanderwart [8]. Estas imagens representam objectos concretos, delimitados por traços pretos (ver figura 22).

As imagens deste conjunto foram escolhidas por cumprirem um conjunto de heurísticas que oferecem coerência na sua representação pictórica, assim como na relevância do processo cognitivo e acesso à memória do indivíduo.



Figura 21- Seis imagens do conjunto de Snodgrass & Vanderwart

A experiência visual decorrida para aquisição dos EEGs/VEP de cada indivíduo foi a seguinte:

Foi pedido aos indivíduos que reconhecessem as imagens assim que estas fossem apresentadas. A duração de cada imagem era de 300ms, com um intervalo entre imagens de 5,1 (segundos) em que não era apresentado imagem (ecrã em branco). Todos os estímulos foram diferentes e apresentados através de um monitor CRT situado a uma distância de um metro dos olhos do indivíduo.

Para cada VEP encontra-se guardado no *dataset* a amplitude dos sinais, adquiridos pelos 64 canais (eléctrodos), durante 1 segundo após o instante em que é apresentado o estímulo.



Figura 22- Experiência visual a decorrer durante a aquisição dos sinais EEG

Na figura 24 é possível observar o sinal EEG adquirido durante um evento, 64 canais x 256 amostras (1 segundo). O instante inicial corresponde ao momento em que ocorre a apresentação de um estímulo ao indivíduo.

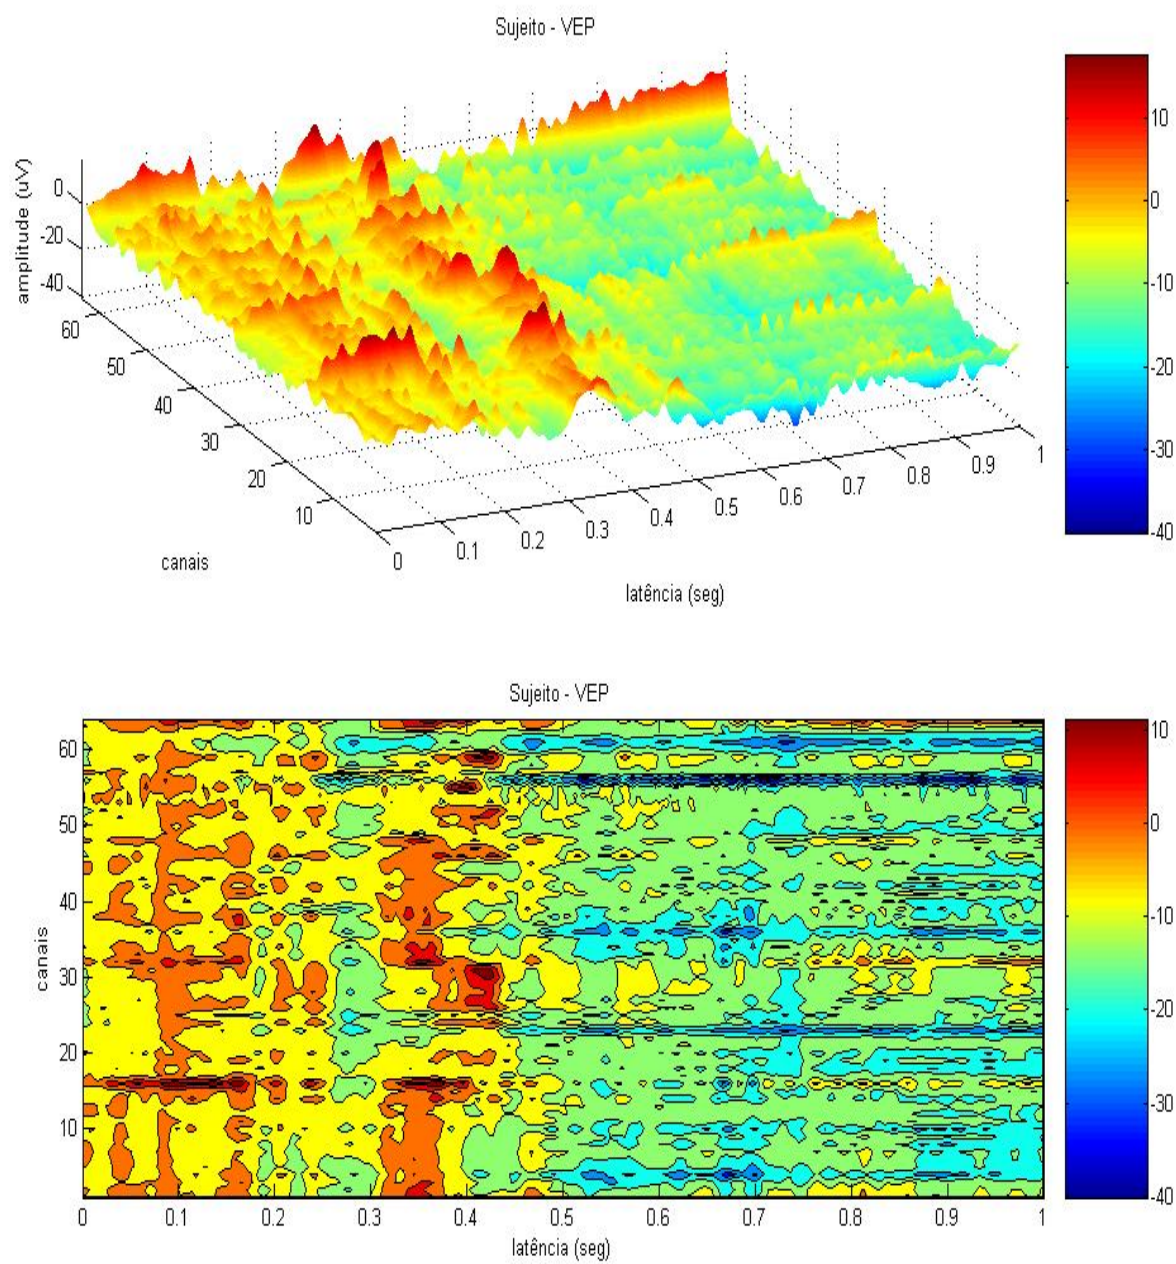



Figura 23- Amplitude dos sinais EEGs, captados por 64 canais, durante a visualização de uma imagem

4.1.1 Estrutura de dados usada para representar o *dataset*

Como os dados que constituem este *dataset*, no seu formato original, se encontram separados em vários ficheiros, um para cada indivíduo, foi necessário ler a informação relevante de todos estes ficheiros e convertê-la num formato passível de uso no Matlab®.

Para tal, foi desenvolvido um script em Matlab® (*file2dataset.m*) que percorre todos os ficheiros do *dataset* e guarda a informação correspondente numa estrutura de dados de matlab que se optou por designar “dataset”.

A estrutura de dados adoptada foi a seguinte:



Em formato C:

```
struct dataset
{
    pessoaStruct pessoa[70]; /*número de pessoas no dataset*/
};
struct pessoaStruct
{
    trialStruct trial[45]; /* número de eventos (VEP) por indivíduo */
};
struct trialStruct
{
    float data[8][256]; /* sinais VEPs adquiridos em cada trial,
                        8 canais x 256 samples (1seg) */
};
```

4.2 Processamento do sinal EEG e extracção das suas características biométricas

Nesta fase ocorre o processamento dos VEP gravados, de forma a extrair destes, a informação relevante para o processo de autenticação biométrica de cada indivíduo.

4.2.1 Ajuste da média do evento para zero

Após a aquisição dos sinais EEG no intervalo de tempo em que ocorre o VEP (1 Seg. após apresentação do estímulo visual), é efectuado um ajuste da amplitude de cada sinal EEG, para que este passe a possuir média zero. Este passo revelou-se necessário para retirar do sinal as altas amplitudes de baixas frequências (0.5 – 2Hz), causadas por fontes externas, tais como calor e campos electromagnéticos, que poderiam vir a interferir com a posterior detecção de artefactos.

4.2.2 Rejeição de eventos com artefactos

Artefactos em electroencefalografia são definidos como todo o potencial eléctrico proveniente de outra fonte que não o cérebro, mas que são captados pelos eléctrodos colocados no escalpe do indivíduo.

Os artefactos de ocorrência mais comum são os instrumentais, tais como a má conectividade dos eléctrodos, campos electromagnéticos gerados por aparelhos eléctricos, etc. e os fisiológicos que incluem movimentos corporais, tais como o “piscar de olhos”, movimentos oculares, musculares, respiratórios e batimento cardíaco.

Como os artefactos podem alterar substancialmente os resultados de análise espectral e a sua disposição topográfica, deve-se evitar a inclusão dos VEP que possuam artefactos.

O método de detecção de artefactos adoptado neste estudo baseia-se na aplicação de um limiar para verificar quais os sinais EEG cuja amplitude excede o seu valor.

Este método é viável para o estudo em questão, uma vez que a maior parte dos artefactos existentes no EEG (piscar de olhos e movimentos oculares) provocam latências no sinal EEG de aproximadamente 200 ms na qual a amplitude do sinal é bastante superior ($> 50 \mu\text{V}$) à de um sinal EEG normal ($0 \sim 40 \mu\text{V}$). Definindo o limiar para o valor de $50\mu\text{V}$ é possível identificar todos os eventos em

que ocorrem os artefactos referidos e desta forma remover estes eventos do do resto do processo de autenticação. Embora outros tipos de artefactos, tais como o o batimento cardíaco (ECG), não sejam detectados pelo método adoptado, considera-se que este não afectam de forma grave a topologia dos EEGs considerados, não interferindo assim com o resto do processo.

Note que, os artefactos causados por interferência das linhas de tensão não foram considerados, pois estes ocorrem na frequência 60Hz (USA) e os sinais EEG foram adquiridos por hardware com filtragem na banda de frequências 0.1 - 50 Hz, não ficando assim registados nos sinais gravados.

Na figura 25 é apresentado um dos eventos que foi removido do *dataset* por conter um artefacto. Este ocorre por volta dos 800 ms após a apresentação do estímulo, muito provavelmente devido a um piscar de olhos, uma vez que ocorre nos canais frontais (F5, F6) e frontais parietais (FP1, FP2) e possui amplitudes muito acima dos 50uV com uma latência de aproximadamente 200 ms.




Figura 24 - Evento com ocorrência de artefactos

4.2.3 Extracção da banda de frequências *Gama* (30-50 Hz)

Nesta fase são extraídos, dos sinais EEG correspondentes a cada VEP, a banda de frequências *Gama* (30 – 50 Hz), pois é nesta banda de frequências que irão ser computadas as características biométricas, que posteriormente irão permitir autenticar cada indivíduo.

A escolha desta banda de frequências, deve-se ao facto desta se encontrar directamente relacionada com um estado de actividade mental bastante elevada do indivíduo, tais como a memória, cognição e percepção visual [5,6,7].

Para extrair a banda de frequências *Gama* desejada (30 – 50Hz), foi aplicado um filtro passa-banda de Butterworth, de ordem 10 e fase zero. A resposta com fase zero é conseguida utilizando filtragem “forward e reverse”, que cancela os efeitos da não-linearidade da fase do filtro Butterworth.

O filtro criado possui assim uma passa-banda nos 3dB, fixa entre os 30-50 Hz, com bandas de corte nos 28Hz e 52 Hz e atenuação de 20dB (ver Figura 25).




Figura 25 - Resposta em magnitude e frequência do filtro butterworth de ordem 10 aplicado.

Nas Figuras Figura 27 e Figura 28 é possível observar um sinal EEG, antes e depois de aplicado o filtro passa-banda de *Butterworth*, referido anteriormente. Como se pode observar nas figuras, um sinal EEG, antes de processado, possui a maior parte do seu espectro de potência na banda de frequências (0 – 30 Hz). Após a aplicação do filtro Butterworth, o sinal EEG sofre uma atenuação de 20 dBs nas frequências de corte 28 Hz e 32 Hz, passando a possuir o maior espectro de potencia na banda *Gama* (30 – 50 Hz).

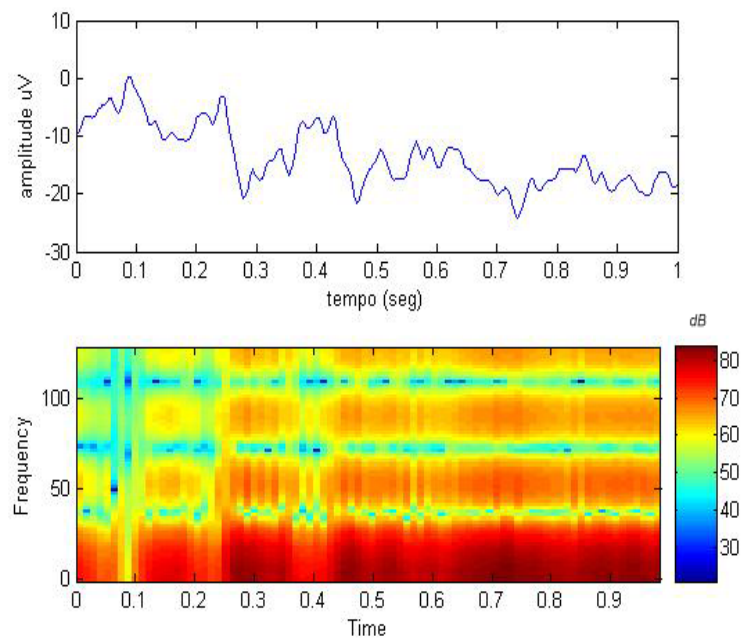


Figura 267 – EEG e o seu espectro de potência, antes de aplicado o filtro Butterworth




Figura 288 – EEG e o seu espectro de potência, depois de aplicado o filtro Butterworth

4.2.4 Composição dos sinais VEP extraídos

A composição dos sinais VEP extraídos surgiu com o intuito de oferecer ao classificador, mais informação do que aquela presente nos 8 sinais individuais considerados. Assim, relacionando os 8 sinais entre si é pretende-se obter outras características biométricas que complementam a energia da banda Gama dos 8 sinais individuais.

A nossa abordagem consistiu em relacionar todos os pares de sinais, subtraindo um sinal ao outro, pois a subtração de sinusoidais com a mesma frequência e amplitude produz um sinal não nulo, cuja variação de amplitude é apresentada em função do desfaseamento das sinusoidais ou diferenças de fase. Desta forma, para além da energia presente na banda Gama de cada sinal EEG isolado é também oferecido, ao vector de características, informação relativa às diferenças de fase entre todos os pares de sinais EEG considerados.

Para calcular os vectores de características foram usados os sinais EEG, adquiridos por C canais, extraídos na banda Gama, em conjunto com C' sinais compostos, resultantes da subtração de pares dos sinais EEG referidos. O vector de características é então constituído por $C + C_{c,2}$ sinais. Como estamos apenas a considerar $C = 8$ (número de canais usados) o nosso vector de características possuirá $C' = 36$ sinais.




Figura 30 – Os 36 sinais VEP compostos : 8 sinais VEP na banda gamma + 28 sinais resultantes das diferenças entre os pares de sinais.

4.2.5 Cálculo da energia dos sinais VEP para cada evento

Nesta fase é efectuado o cálculo da energia dos 36 sinais presentes no vector de características, extraídos até ao momento. Para o cálculo da energia dos sinais compostos, é aplicado, a cada sinal, o teorema da equivalência tempo-frequência de Parseval,

$$E(s) = \frac{1}{N} \sum_{n=1}^N x(s)_n^2$$

onde x é um sinal do vector de características e N o número de amostras presentes no sinal. Após computadas as energias de cada sinal, o vector de características de cada indivíduo, passa a possuir o valor de 36 energias, uma por cada sinal que constituía este vector.

4.2.6 - Normalização da energia do sinal

Por último, os valores das energias presentes no vector de características são normalizados com maior valor de energia presente no vector correspondente.

$$F [1 \dots C'] = \frac{E [1 \dots C']}{\max (E [1 \dots C'])}$$

Esta fase de normalização revela-se necessária, uma vez que, um dos requisitos apresentados pelos classificadores adoptados, é o facto de que todos os valores dos vectores a serem classificados deverem se encontrar no intervalo de valores [0, 1].




Figura 31- Exemplo de um vector de características extraído (energia normalizada dos 36 sinais)

4.3 Classificação e Análise das Características Extraídas

Nas secções anteriores, foi apresentado todo o processo de extracção aplicado aos sinais EEG dos indivíduos, de forma a retirar destes a informação biométrica que permita autenticar cada indivíduo.

Após extraídas as características biométricas dos VEPs de cada indivíduo, obtemos um novo *dataset* [70 indivíduos x 45 estímulos], onde a célula [x,y], corresponde aos 36 valores da energia normalizada, extraídos da pessoa x, após a sua visualização de um estímulo y (ver figura 31).

4.3.1 Análise Visual das Características Extraídas

Nesta secção, pretende-se verificar que as características extraídas durante o processo anterior, possuem as propriedades intrínsecas a uma característica biométrica, ou seja, se estas apresentam sempre o mesmo padrão para cada indivíduo, e padrões diferentes entre indivíduos.

Na figura 32, são apresentados 30 vectores de características extraídos de 10 pessoas diferentes. Note que embora os vectores de características sejam compostos por valores discretos (ver figura. 31), nesta fase optou-se por fazer a sua representação gráfica com valores contínuos de forma a facilitar a sua visualização, evitando assim que a sobreposição dos 30 vectores se torne muito confusa.

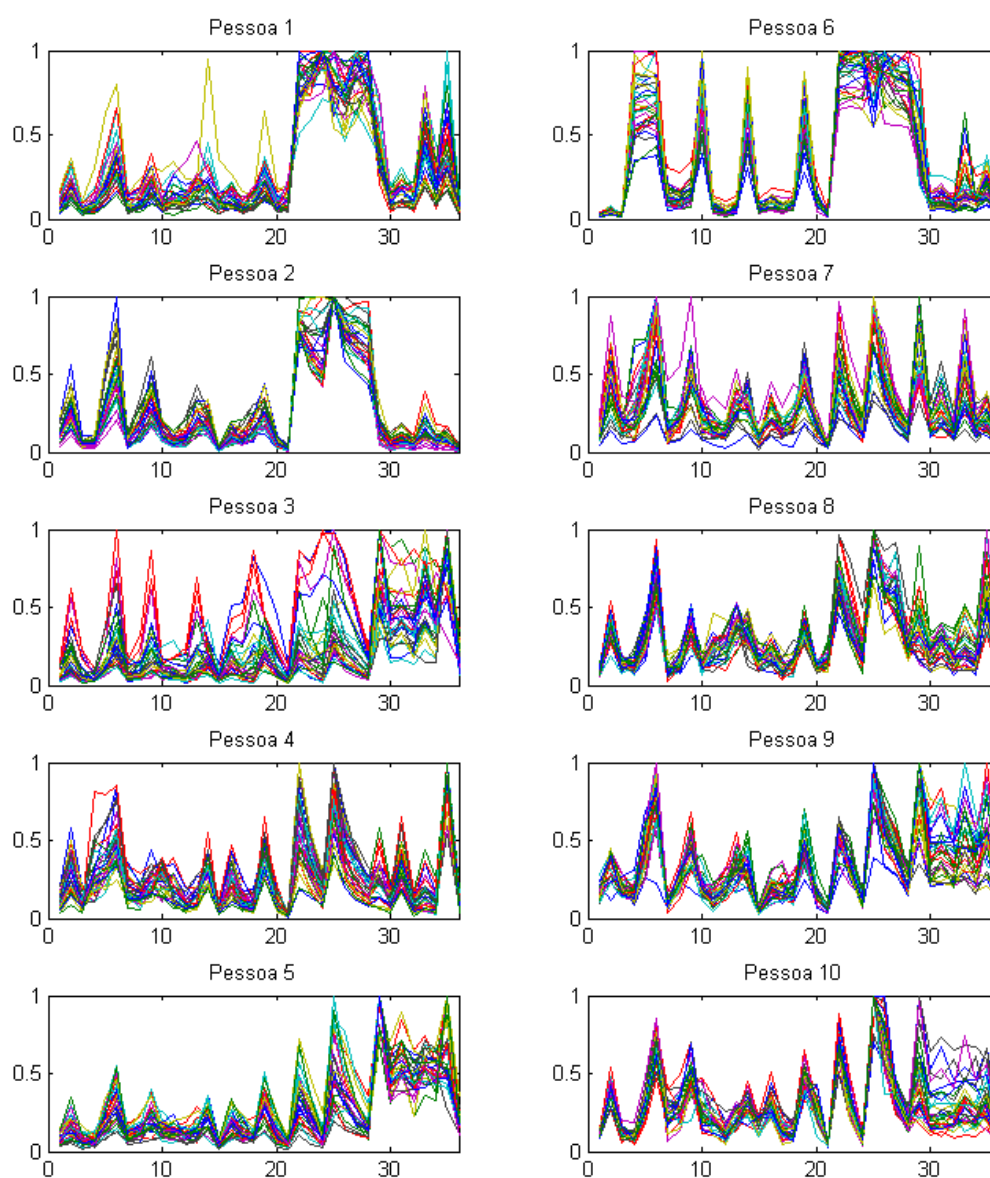


Figura 32- vectores de características extraídos de 10 pessoas diferentes

Pela observação dos vectores extraídos de 10 pessoas, podemos verificar que os padrões apresentados por estes são muito semelhantes para o mesmo indivíduo e diferentes para indivíduos diferentes, sendo assim pouco provável que um indivíduo possua um vector com um padrão de valores iguais ao de outro indivíduo. Podemos assim concluir que as características extraídas dos sinais EEG, apresentam uma qualidade intrínseca a uma característica biométrica, a unicidade.

4.3.2 Treino e Teste dos OCCs com os Vectors de Características Extraídos

Nesta secção, os 45 vectores de características de cada indivíduo foram usados para treinar e testar os classificadores propostos, de modo a verificar se estas características são, ou não, passíveis de serem usadas num sistema de autenticação biométrica.

Como já foi referido, para o processo de autenticação, foi considerado um classificador por indivíduo. Considerando a população de 70 pessoas, disponíveis pelo *dataset*, foram usados 70 classificadores. A pessoa que cada classificador deverá considerar como correcta será designada por dono do classificador, logo, cada classificador é treinado para reconhecer somente as características do seu dono e rejeitar as características de qualquer outra pessoa.

Para treinar cada classificador foram usados no máximo 30 vectores de características extraídos do seu dono, note que para algumas pessoas o número de vectores usados para treino é relativamente menor, devido à quantidade de eventos rejeitados por conterem artefactos.

Durante o treino de cada classificador este estabelece internamente um conjunto de propriedades que lhe permite reconhecer dois domínios de classes diferentes, a classe alvo e a classe exterior (Verdadeiro e Falso).

Acesso	Saída do OCC	
	VERDADEIRO	FALSO
Dono do classificador	Correcto (verdadeiro positivo)	Erro (falso negativo)
Não dono do classificador	Erro (falso positivo)	Correcto (falso positivo)

Após cada classificador ser treinado com os vectores do seu dono, este é testado com 15 vectores de características do seu dono e com outros 15 vectores de características pertencentes a cada um dos outros indivíduos, que não o dono do classificador.

Um factor que varia nas várias simulações realizadas, é não usar somente cada vector de teste individualmente, mas também ter verificado como variam os resultados do classificador, quando um indivíduo, em vez de se autenticar com apenas a visualização de um estímulo, usar a média de n vectores de características extraídos após a visualização de n estímulos independentes.

Usando a média de vários estímulos, em vez de estímulos individuais, pretende-se diminuir as ocorrências de variações nos valores dos vectores de características, causadas por diferentes reacções cognitivas a imagens diferentes.

Para simular este cenário, o novo conjunto de teste considerado para cada pessoa, é composto pelos vectores médio dos k subconjuntos resultantes da computação de combinações simples do conjunto de teste.

Combinações simples de n elementos tomados k a k são subconjuntos formados por k elementos distintos escolhidos entre os n elementos dados, considerando que duas combinações são diferentes quando possuem elementos distintos. Por exemplo, considere:

Conjunto Z	$Z = \{A, B, C\}$	$n = 3$
Nº de elementos dos subconjuntos	$k = 2$	Taxa de 2 elementos
Grupos de Combinação Simples	$\{AB, AC, BC\}$	$C_{n,k}$
Número total de Subconjuntos	$C_{n,k} = n! / k!(n-k)!$	$C_{3,2} = 3! / 2!(3-2)! = 3$

Em analogia com a tabela apresentada, os elementos A, B e C representam 3 diferentes vectores de características de um indivíduo. Desta forma, para cada subconjunto vai ser calculado o vector com a média dos valores dos vectores que lhe pertencem, ou seja $\{AB, AC, BC\}$ passa a ser $\{\text{média } \{A,B\}, \text{média } \{A,C\}, \text{média } \{B,C\}\}$.

Com a aplicação de combinações simples, o número de vectores de cada indivíduo, usados para teste do classificador, aumenta de acordo com a fórmula do número binomial:

$$({}^n_k) = n! / k!(n-k)!$$

Combinação de vectores	Número de vectores de teste resultantes das combinações	
	Total	Pertencentes ao Dono
Singulares	$70 \times 15 = 1050$	15
Pares	$70 \times C_{15,2} = 7350$	105
Trios	$70 \times C_{15,3} = 31850$	455

Usando, para teste, a média de n vectores, em vez de um só, permite que estes apresentem uma melhor definição relativa ao domínio que representa a sua classe.

Repare que não se optou por aplicar o mesmo método ao conjunto de treino, pois pretende-se que o classificador não defina uma fronteira muito restrita à classe alvo, para que este, posteriormente, ofereça alguma margem de aceitação nos futuros vectores da classe alvo a considerar.

Nas Figuras Figura 32 a Figura 34 pode-se observar os vectores de características, extraídos de 4 pessoas diferentes, usados para treino do seu classificador (esquerda), para teste com vectores individuais (centro) e para teste com média dos vectores combinados dois a dois (direita). Como se pode verificar nas figuras apresentadas, a variância entre vectores de características é menor quando é usada a média de n vectores, o que implica uma maior constância entre vectores.




Figura 33 - Vectores usados para treino




Figura 34 - Vectores de teste simples




Figura 35 - Vectores de teste combinados dois a dois

5 Resultados e discussão

Nesta secção serão apresentados e discutidos os resultados obtidos, após a classificação dos vectores dos 70 indivíduos, pelos 70 classificadores.

5.1 - Receiver Operating Characteristic curve (curva ROC)

Um bom indicador sobre o desempenho de um OCC, é a representação gráfica da sua curva ROC. Esta curva mostra de que forma varia a taxa de falsos positivos relativamente à taxa de verdadeiros positivos e é calculada através da realização de vários testes do OCC com diferentes valores de *fr* aplicado às fronteiras que delimitam a classe alvo.

Um OCC com bom desempenho é aquele que estabelece fronteiras de forma a maximizar a taxa de verdadeiros positivos e minimizar a taxa de falsos positivos. Esta característica de um OCC pode ser quantitativamente avaliada através do cálculo da área delimitada pela sua curva ROC, também conhecida por *Area Under Curve* (AUC) [2].

A figura 35 seguinte apresenta as curvas ROC geradas pelos classificadores dos 70 indivíduos, assim como o valor médio das AUC obtidas pelas curvas ROC dos 70 classificadores. As curvas foram obtidas quando testados os OCC com a média de trios de vectores.

Pela observação das ROCs, obtidas por cada tipo de OCC considerado, podemos verificar que os classificadores AND e OR são aqueles que possuem, em média, a AUC mais alta, logo são os que apresentam a melhor relação entre taxas de verdadeiro positivos e falsos positivos na classificação dos vectores de teste.

Note que na aplicação prática de um OCC, é necessário definir um valor de limiar (fracção de rejeição), pois apenas um valor da curva ROC é considerado pelo OCC. No estudo seguinte foram considerados 3 valores de fracção de rejeição diferentes, 0.2, 0.5 e 0.7, de forma a verificar o seu impacto nos resultados das classificações.

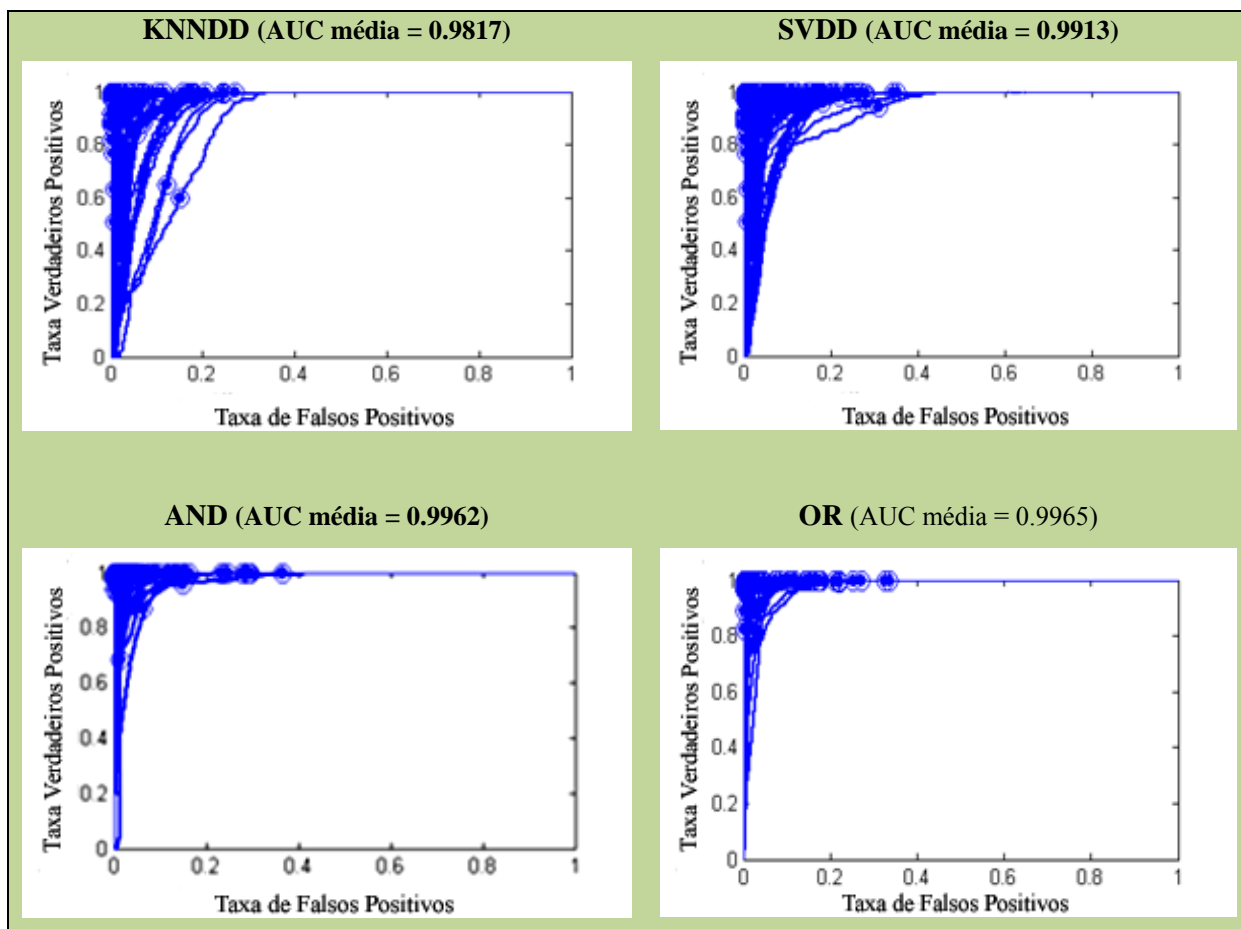


Figura 36 – curvas ROC obtidas, por cada tipo de OCC considerado, após classificação dos vetores de teste.

5.2 Resultados Gerais

Nesta secção são apresentadas as médias de classificações correctas do dono do classificador (verdadeiros positivos) e as incorrectas dos não donos do classificador (falsos positivos), obtidas pelos 70 classificadores após estes terem sido testados com os vectores de características dos 70 indivíduos.


Cada simulação foi realizada dez vezes no total, para cada simulação foram usados diferentes vectores de características do dono do classificador para treino e teste, e diferentes vectores dos outros indivíduos para teste³.

De seguida são apresentados as médias dos resultados obtidos por cada tipo de OCC considerado, após a classificação de todos os indivíduos. Os resultados obtidos são apresentados em função do valor de fr aplicado durante a fase de treino do classificador e do número de vectores usados para calcular a média dos vectores de características usados para teste. Entre parêntesis encontram-se os valores do desvio padrão entre os resultados obtidos pelos 70 classificadores após os dez testes efectuados.

³ Os resultados avaliados para o cálculo das médias de cada classificador, encontram-se detalhados nos ficheiros Excel® que seguem em anexo com este documento.


KNDD	Classificações correctas dos Donos (% verdadeiros positivos)			Classificações incorrectas dos não Donos (% falsos positivos)		
	1 vector	2 vectores	3 vectores	1 vector	2 vectores	3 vectores
<i>fr</i>						
0.2	78.7 (13.1)	90.6 (7.5)	95.1 (5.3)	5.2 (1.3)	5.6 (1.6)	6.4 (1.9)
0.5	50.1 (15.9)	65.3 (9.3)	74.1 (8.6)	1.9 (0.7)	2.2 (0.9)	2.3 (1.3)
0.7	31.3 (18.5)	46.1 (11.3)	66.3 (9.8)	0.9 (0.4)	1.1 (0.5)	1.3 (0.7)

SVDD	Classificações correctas dos Donos (% verdadeiros positivos)			Classificações incorrectas dos não Donos (% falsos positivos)		
	1 vector	2 vectores	3 vectores	1 vector	2 vectores	3 vectores
<i>fr</i>						
0.2	76.1 (12.8)	95.2 (4.9)	98.5 (3.5)	5.7 (1.8)	8.5 (2.1)	10.1 (3.2)
0.5	58.5 (17.4)	88.3 (8.7)	93.7 (5.7)	2.8 (1.6)	4.4 (1.8)	5.1 (2.7)
0.7	44.2 (20.5)	77.7 (12.3)	85.3 (9.8)	1.7 (1.6)	2.6 (1.7)	3.6 (1.9)



AND	Classificações correctas do Dono (% verdadeiros positivos)			Classificações incorrectas do não Dono (% falsos positivos)		
	1 vector	2 vectores	3 vectores	1 vector	2 vectores	3 vectores
<i>fr</i>						
0.2	83.3 (11.2)	96.4 (4.5)	99.1 (1.8)	4.5 (1.2)	6.2 (1.6)	6.8 (1.8)
0.5	60.4 (15.1)	85.6 (9.9)	92.8 (7.3)	1.2 (0.6)	1.7 (0.7)	1.9 (0.9)
0.7	37.8 (17.6)	68.4(15.7)	79.4(14.1)	0.4 (0.3)	0.6 (0.4)	0.6 (0.5)

OR	Classificações correctas do Dono (% verdadeiros positivos)			Classificações incorrectas do não Dono (% falsos positivos)		
	1 vector	2 vectores	3 vectores	1 vector	2 vectores	3 vectores
<i>fr</i>						
0.2	83.8 (10.1)	96.5 (3.9)	99.1 (1.7)	4.7 (1.2)	6.2 (1.6)	6.8 (1.7)
0.5	59.7 (15.9)	85.7 (10.6)	92.8 (7.9)	1.2 (0.5)	1.7 (0.7)	1.9 (0.8)
0.7	38.7 (16.9)	69.8 (15.4)	80.4 (13.3)	0.4 (0.3)	0.6 (0.4)	0.6 (0.4)



A primeira e mais evidente conclusão que se retira através da visualização dos gráficos e tabelas apresentados, é a elevada taxa de sucesso obtida (verdadeiros positivos e verdadeiros negativos), independentemente do tipo de classificador adoptado.

Relativamente ao valor de fr usado, observou-se o impacto nas taxas de classificações que já era esperado [2]. Para valores de fr baixos, o classificador é menos exigente e aceita uma maior taxa de verdadeiros positivos assim como de falsos positivos, enquanto que para valores de fr mais elevados, o classificador é mais exigente e aceita uma menor taxa de verdadeiros positivos assim como de falsos positivos.

Considerando o número de vectores computados para obter a média dos vectores usados para teste, verificou-se que, quantos mais vectores forem considerados no cálculo desta média, maior é a taxa de classificações correctas do dono do classificador, embora que isso implique também um ligeiro aumento no falso reconhecimento de outros indivíduos que não o dono (falsos positivos).

Comparando os classificadores KNNDD e SVDD, verifica-se que o classificador KNNDD é aquele que possui uma taxa de falsos positivos mais baixa, no entanto isso também implica uma menor taxa de verdadeiros positivos. O SVDD possui um comportamento inverso ao do KNNDD, i.e. procura maximizar a taxa de classificações correctas do dono do classificador, acabando por aceitar uma maior taxa de falsos positivos.

Para os classificadores combinados, AND e OR, verifica-se que qualquer um destes apresenta melhores resultados do que quando usados o KNNDD ou o SVDD individualmente. Os resultados obtidos por cada um dos classificadores combinados considerados são bastante semelhantes, assim podemos concluir que para ambas as combinações, as saídas dos classificadores, após complementadas, apresentam quase sempre o mesmo resultado.

5.3 Resultados dos classificadores individuais

Analizados os resultados obtidos em média pelos 70 classificadores, vamos verificar como variam os resultados obtidos para o classificador de cada pessoa.

Os gráficos seguintes apresentam a média das classificações, correctas e incorrectas, obtidas por cada classificador, após a realização de 10 testes independentes. Para cada teste realizado foram usados diferentes vectores do dono do classificador para treino e teste, assim como diferentes vectores dos outros indivíduos somente para teste. Por uma questão de espaço, apenas os gráficos dos classificadores OR e AND são apresentados, uma vez que são os que apresentam melhores resultados.



Nos gráficos seguintes, a linha verde corresponde à taxa de classificações correctas do dono do classificador (verdadeiros positivos) e a linha vermelha à taxa de classificações incorrectas de outra pessoa que não o dono do classificador (falsos positivos). As linhas verticais indicam qual o valor máximo e mínimo usado no cálculo dos valores médios. Os resultados são apresentados em função do valor de fr aplicado ao conjunto de treino e do número de vectores combinados para cálculo dos conjuntos de teste.

$fr = 0.2$



AND

OR



1 Vector



2 Vectors



3 Vectors





$fr = 0.5$



AND

OR



1 Vector



2 Vectors





3 Vectors





AND

OR



1 Vector



2 Vectors



3 Vectors



Como se pode verificar pelos gráficos apresentados, os classificadores pertencentes aos vários indivíduos não possuem todos a mesma taxa de classificações correctas e incorrectas. Isto deve-se ao facto de que alguns indivíduos possuem características mais singulares e constantes do que outros. Desta forma as suas classificações não variam tanto quando executados treinos e testes com diferentes conjuntos de vectores.

Mais uma vez, é possível verificar que aumentando o número de vectores, usados para calcular a média do vector de teste, a taxa de verdadeiros positivos aumenta significativamente, muito embora a taxa de falsos positivos também aumente um pouco.

Quanto ao valor de fr , aplicado aos conjuntos de treino verificou-se que, para valores baixos de fr o classificador possui uma maior taxa de classificações correctas do seu dono (verdadeiros positivos), assim como uma maior taxa de pessoas que não o dono do classificador (falsos positivos), enquanto que para valores de fr mais elevados o classificador aceita uma menor taxa de classificações correctas do seu dono (verdadeiros positivos) e uma menor taxa de pessoas que não o dono do classificador (falsos positivos). Isto acontece porque o valor de fr afecta directamente as fronteiras de decisão aplicadas à classe alvo, ou seja, valores de fr baixos implicam fronteira menos restritas à classe alvo e valores de fr altos implicam fronteiras mais restritas.

6 Conclusão

Esta tese apresenta um método inovador para efectuar a autenticação biométrica de indivíduos através do uso dos seus sinais EEG.

Os sinais EEG considerados neste estudo foram gravados durante um curto período em que os indivíduos visualizavam uma imagem, capturando assim um fenómeno electro-fisiológico, que ocorre com maior incidência na zona occipital do córtex cerebral, conhecido por potencial visual evocado (VEP).

O estudo realizado neste documento distingue-se de todos os outros estudos relacionados com esta área, pois apresenta uma série de inovações que visam oferecer a este sistema mais usabilidade e qualidade:

- Apenas 8 canais (eléctrodos) foram considerados. Estes 8 canais situam-se na zona occipital do cérebro, que se encontra directamente relacionada com a cognição e percepção de estímulos visuais. Em comparação com os 61 canais usados noutros estudos, esta alteração acaba por ser um grande passo alcançado no aumento da usabilidade e colectabilidade deste sistema.
- Foram usadas as diferenças entre pares de sinais EEG de forma a oferecer aos vectores de características mais informação sobre cada indivíduo, uma vez que os sinais resultantes das diferenças reflectem diferenças de fase entre os sinais EEG originais.
- Para classificação das características extraídas foram usados OCC em vez de outros tipos de classificadores. O uso de OCC é mais adequado a um cenário de autenticação, uma vez que estes só precisam de ser treinados com as características biométricas da pessoa a ser reconhecida como verdadeira. Desta forma, foi considerado que cada pessoa possui um OCC, previamente treinado por si, para a reconhecer.
- O OCC de cada pessoa é treinado com vectores singulares de características, mas é testado usando a média de dois ou mais vectores. Desta forma a variação entre os valores dos vários vectores torna-se menos significativa, resultando em classificações mais correctas.

Os resultados obtidos, após a classificação dos vectores de características extraídos dos 70 indivíduos, demonstraram que, os VEP originados por estimulação visual de indivíduos são passíveis de uso como característica biométrica, sendo possível através destes identificar singularmente cada pessoa.

Considerando o grupo de 70 pessoas usado neste estudo, quando se usam as médias de 3 vectores e os classificadores combinados, conseguem-se classificações muito exactas, nomeadamente, altas taxas de verdadeiros positivos (99.1 ~ 80.5) e baixas taxas de falsos positivos (6.8 ~ 0.6).

Verificou-se também que a taxa de classificações correctas obtida por cada pessoa é razoavelmente estável, o que nos oferece um bom indicador sobre a universalidade e unicidade das características biométricas consideradas neste estudo. Note-se que estes bons indicadores de qualidade foram obtidos usando uma técnica simples de detecção de artefactos (amplitudes do sinal acima de um limiar de 50 μ V)

Finalmente, o sistema de autenticação apresentado possui vários parâmetros internos, tais como o valor de fracção de rejeição, que podem ser usados para personalizar cada classificador de forma a garantir a melhor taxa de classificações associada a cada indivíduo.

Para tornar este estudo mais abrangente faltou considerar uma propriedade das características biométricas extraídas, a sua constância ao longo do tempo. Uma vez que os VEPs, considerados neste estudo, foram gravados em intervalos de tempo muito reduzidos, estes não reflectem as possíveis alterações fisiológicas e mentais, tais como fadiga, stress, cansaço, etc., que podem ocorrer nos indivíduos quando considerados maiores intervalos de tempo (meses, anos) ou mesmo ao longo do dia.

7 Referências Bibliográficas

- [1] A. Jain, L. Hong, and S. Pankanti, "Biometric Identification," *Communications of the ACM*, vol. 43, no. 2, pp. 90–98, 2000.
- [2] D. M. J. Tax, *One-class classification; Concept-learning in the absence of counter-examples*. PhD thesis, Delft University of Technology, Delft, Netherlands, June 2001.
- [3] E. Basar, C. Basar-Eroglu, T. Demiralp, and M. Schürmann, "Time and Frequency Analysis of the Brain's Distributed Gamma-Band System," *IEEE Eng. in Medicine and Biology*, vol. 14, pp. 400–410, July 1995.
- [4] A. Keil, M. M. Muller, W. J. Ray, T. Gruber, and T. Elbert, "Human Gamma Band Activity and Perception of a Gestalt," *The J. of Neuroscience*, vol. 19, pp. 7152–7161, Aug. 1999.
- [5] W. Lutzenberger and F. Pulvermüller and T. Elbert and N. Birbaumer, "Visual stimulation alters local 40-Hz responses in humans: an EEG-study," *Neuroscience Letters*, vol. 183, pp. 39–42, Jan. 1995.
- [6] C. Tallon-Baudry, O. Bertrand, F. Peronnet, and J. Pernier, "Induced γ -Band Activity during the Delay of a Visual Short-Term Memory Task in Humans," *The J. of Neuroscience*, vol. 18, pp. 4244–4254, June 1998.
- [7] T. Gruber, M. M. Müller, and A. Keil, "Modulation of Induced Gamma Band Responses in a Perceptual Learning Task in the Human EEG," *J. of Cognitive Neuroscience*, vol. 14, no. 5, pp. 732–744, 2002.
- [8] J. G. Snodgrass and M. Vanderwart, "A Standardized Set of 260 Pictures: Norms for Name Agreement, Image Agreement, Familiarity and Visual Complexity," *Journal of Experimental Psychology: Human Learning and Memory*, vol. 6, no. 2, pp. 174–215, 1980.
- [9] E. Basar, "Relation between EEG and Brain Evoked Potentials," in *EEG-Brain Dynamics*, Amsterdam: Elsevier, North-Holland biomedical Press, 1980.
- [10] E. Basar, B. Rosen, C. Basar-Eroglu, and F. Greitschus, "The associations between 40 Hz-EEG the Middle Latency Response of the Auditory and Evoked Potential," *The Int. J. of Neuroscience*, vol. 33, no. 1-2, pp. 103–117, 1987.
- [11] R. Galambos, "A comparison of certain gamma band (40-Hz) brain rhythms in cat and man," in *Induced Rhythms in the Brain*, pp. 201–216, Boston, MA, USA: Birkhäuser, 1992.
- [12] M. Poulos, M. Rangousi, and E. Kafetzopoulos, "Person identification via the EEG using computational geometry algorithms," in *Proc. Of the 9th European Signal Processing (EUSIPCO'98)*, (Rhodes, Greece), pp. 2125–2128, 1998.
- [13] M. Poulos, M. Rangoussi, V. Chrissikopoulos, and A. Evangelou, "Person Identification Based on Parametric Processing of the EEG," in *Proc. of the 6th IEEE Int. Conf. on Electronics, Circuits and Systems (ICECS)*, pp. 283–286, 1999.

- [14] Paranjape,R.B.,Mahovsky,J., Benedicenti,L., and Koles,Z.: The electroencephalogram as a biometric . Proc. Canadian Conf. on Electrical and Computer Engineering,Toronto,ON,13 16 May 2001, Vol. 2,pp. 1363 1366
- [15] R. Palaniappan, "Method of identifying individuals using VEP signals and neural network," IEE Proc. - Science Measurement and Technology, vol. 151, no. 1, pp. 16–20, 2004.
- [16] R. Palaniappan and D. P. Mandic, "Energy of Brain Potentials Evoked During Visual Stimulus: A New Biometric," in Proc. of the Int. Conf. on Artificial Neural Networks: Formal Models and Their Applications (ICANN 2005), LNCS 3697, pp. 735–740, Springer, Aug. 2005.
- [17] K. V. R. Ravi and R. Palaniappan, "Recognising Individuals Using Their Brain Patterns," in Proc. of the 3th Int. Conf. on Information Tech. and Applications (ICITA'05), IEEE Computer Society, 2005.
- [18] K. V. R. Ravi and R. Palaniappan, "Leave-one-out Authentication of Persons Using 40 Hz EEG Oscillations," in Proc. of the Int. Conf. on "Computer as a tool" (EUROCON 2005), (Belgrade, Serbia & Montenegro), Nov. 2005.
- [19] K. V. R. Ravi and R. Palaniappan, "Neural network classification of late gamma band electroencephalogram features," Soft Computing, vol. 10, pp. 163–169, 2006.
- [20] R. Palaniappan and D. P. Mandic, "EEG Based Biometric Framework for Automatic Identity Verification," Journal of VLSI Signal Processing, vol. 49, pp. 243–250, 2007.
- [21] J. L. Elman, "Finding structure in time," Cognitive Science, vol. 14, pp. 179–211, April/June 1990.
- [22] T. Kasuba, "Simplified Fuzzy ARTMAP," AI Expert, pp. 18–25, 1993.
- [23] D. Davies and D. Bouldin, "A Cluster Separation Measure," IEEE Trans. on Pattern Analysis and Mach. Intelligence, vol. 1, no. 2,pp. 224–227, 1979.
- [24] R. Sivakumar and G. Ravindran, "Identification of Intermediate Latencies in Transient Visual Evoked Potentials," Academic Open Internet Journal, vol. 17, 2006.
- [25] Zhang, X.L., Begleiter, H., Porjesz, B., and Litke, A., Electrophysiological Evidence of Memory Impairment in Alcoholic Patients, *Biological Psychiatry*, pp. 1157-1171, vol. 42, 1997.
- [26] Sébastien Marcel and José de R. Millán, "Person Authentication Using Brainwaves (EEG) and Maximum A Posteriori Model Adaptation", "IEEE Trans. on Pattern Analysis and Mach. Intelligence", vol.29 num.4 2007, pages 743-748
- [27] Hong, L.: Automatic personal identification using fingerprints. PhD Thesis, Michigan State University (1998)
- [28] Faculty of Informatics, Masaryk University , "Biometric Authentication Systems" by Zdeněk Růžička Václav Matyáš, FI MU Report Series, FIMU-RS-2000-08.

[29] “EEG Signal Classification for Brain Computer Interface Applications” ECOLE POLYTECHNIQUE FEDERALE DE LAUSANNE, Jorge Baztarrica Ochoa, Responsible Assistant : Gary Garcia Molina. Professor : Touradj Ebrahimi, March 28th, 2002.

[30] O’Brien, R.G. (1979), “A General ANOVA Method for Robust Tests of Additive Models for Variances,” *Journal of the American Statistical Association*, 74, 877–880.